

Національний університет «Запорізька політехніка»

Міністерство освіти і науки України

Харківський національний університет радіоелектроніки

Міністерство освіти і науки України

Кваліфікаційна наукова

праця на правах рукопису

ОЛІЙНИК АНДРІЙ ОЛЕКСАНДРОВИЧ

УДК 004.032.26:004.8

ДИСЕРТАЦІЯ

МЕТОДИ СИНТЕЗУ ДІАГНОСТИЧНИХ МОДЕЛЕЙ НА ОСНОВІ ОБЧИСЛЮВАЛЬНОГО ІНТЕЛЕКТУ

05.13.23 – системи та засоби штучного інтелекту
технічні науки

Подається на здобуття наукового ступеня доктора технічних наук

Дисертація містить результати власних досліджень. Використання ідей,
результатів і текстів інших авторів мають посилання на відповідне джерело

Підпис

А.О. Олійник

Науковий керівник (консультант)

Субботін Сергій Олександрович, доктор технічних наук, професор

Цей примірник дисертації ідентичний за змістом з іншими примірниками,
поданими до спеціалізованої вченої ради Д 64.052.01
Учений секретар спеціалізованої вченої ради Д 64.052.01

Підпис

Є. І. Литвинова

Харків – 2021

АНОТАЦІЯ

Олійник А.О. Методи синтезу діагностичних моделей на основі обчислювального інтелекту. – Кваліфікаційна наукова праця на правах рукопису.

Дисертація на здобуття наукового ступеня доктора технічних наук за спеціальністю 05.13.23 «Системи та засоби штучного інтелекту». – Національний університет «Запорізька політехніка», Харківський національний університет радіоелектроніки, Міністерство освіти і науки України, Харків, 2021.

У дисертаційній роботі вирішено актуальну науково-прикладну проблему розроблення та дослідження методів синтезу діагностичних моделей, які поєднують принципи інтелектуальних та паралельних обчислень, що дозволяє підвищити швидкість процесу побудови діагностичних моделей, збільшити їх інтерпретовність та узагальнювальні можливості.

Об'єктом дослідження є процес діагностування на основі даних. Предметом дослідження є методи синтезу діагностичних моделей в інтелектуальних системах.

Методи дослідження: для вирішення завдань, поставлених у дисертаційній роботі, використано методи кластерного аналізу для виявлення груп компактно розташованих екземплярів при синтезі діагностичних моделей, теорії нейро-нечітких мереж як базис для синтезу діагностичних моделей, теорії паралельних обчислень для розробки паралельних методів редукції даних та синтезу нейро-нечітких діагностичних моделей, стохастичного пошуку та лінійної алгебри для створення нових методів оброблення даних на основі дерев розв'язків, асоціативних правил, негативного відбору та нейро-нечітких мереж, методи математичної статистики для обчислення оцінок індивідуальної значущості ознак в процесі побудови дерев розв'язків, видобування

асоціативних правил та синтезу нейро-нечітких мереж, а також для аналізу ефективності розроблених методів синтезу діагностичних моделей та перевірки достовірності отриманих результатів.

Проведено аналіз та досліджено процес синтезу діагностичних моделей на основі нейро-нечітких мереж, визначено, що наборам діагностичних даних, як правило, властиві наявність пропущених і суперечливих значень, різні типи вхідних атрибутів і вихідного параметру об'єктів вибірки, шумів, неструктурований характер даних, великі обсяги надлишкових даних та інші характеристики, які суттєво уповільнюють, ускладнюють, а в деяких випадках роблять неможливим застосування існуючих методів обробки діагностичних даних. За результатами проведеного аналізу зроблено висновок, що наявність зазначених недоліків обумовлює необхідність розробки нових методів і засобів обробки даних, здатних підвищити швидкість обробки інформації, а також поліпшити узагальнювальні та апроксимаційні властивості діагностичних моделей, синтезованих на основі наявних наборів даних.

У дисертаційній роботі запропоновано стохастичний метод синтезу моделей на основі дерев розв'язків, який використовує інформацію про інформативність ознак, складність синтезованого дерева, а також точність його розпізнавання, що дозволяє на початковому етапі формувати множину деревоподібних структур, які характеризуються простою ієрархією та невисокою помилкою розпізнавання, у процесі пошуку створювати нові множини розв'язків з урахуванням інформації про значущість ознак та інтерпретовність генерованих дерев, що, у свою чергу, забезпечує можливість побудови дерев розв'язків з невеликою кількістю елементів (вузлів і зв'язків між ними) та прийнятною точністю розпізнавання, а також видобувати на його основі найцінніші екземпляри для структурного синтезу діагностичних моделей.

Стохастичний метод видобування чисельних асоціативних правил, удосконалений у дисертаційній роботі, передбачає попереднє виділення термів

як інтервалів значень ознак, враховуючи при цьому ширину діапазону значень і частоту попадання значень ознак у кожний з термів, використовує ймовірнісний підхід для перебору різних сполучень антецедентів і консеквентів асоціативних правил, використовує апріорну інформацію про значущість термів та ознак, що дозволяє обробляти чисельну інформацію при видобуванні правил в процесі структурного синтезу діагностичних моделей, істотно скоротити кількість проходів по заданому набору даних, виявляти правила з високим рівнем вірогідності й інших критеріїв оцінювання їхньої якості.

Запропонований метод синтезу продукційних правил на основі негативного відбору для випадку нерівномірного розподілу екземплярів класів вибірки при генерації набору детекторів використовує відому інформацію про екземпляри всіх класів вибірки, враховує інформацію про індивідуальну значущість ознак, як форму детектора використовує гіперкуб максимально можливого об'єму, що дозволяє виключати малозначущі та надлишкові ознаки з вибірки, скоротивши тим самим простір пошуку і час виконання методу, а також формувати набір детекторів з високими апроксимаційними й узагальнювальними властивостями.

Розроблено паралельний метод видобування продукційних правил на основі обчислювального інтелекту, що здійснює паралельну побудову інтелектуальних моделей, які узагальнюють задані вибірки даних у вигляді моделей на основі дерев розв'язків, асоціативних правил, негативного відбору, що дозволяє скоротити часові витрати на синтез моделей при розв'язанні складних практичних задач, які характеризуються великими обсягами діагностичних даних, а також задач, де виникає необхідність у модифікації вже існуючих діагностичних моделей у зв'язку з отриманням нової інформації в процесі спостережень за станом досліджуваних об'єктів або процесів.

Розроблено паралельний стохастичний метод редукції даних, який передбачає використання різних стратегій стохастичного пошуку, що ґрунтуються на еволюційному і мультиагентному підходах та реалізуються на

різних вузлах паралельної системи, що дозволяє розширити покриття простору пошуку, підвищити різноманітність множини рішень поточної популяції та скоротити час пошуку.

Запропонована модель подання стохастичного пошуку у ярусно-паралельній формі для параметричного синтезу нейро-нечітких мереж відрізняється використанням апріорної інформації про навчальну вибірку та просторове розташування рішень. Це дозволяє більш детально досліджувати області можливих оптимумів та скоротити час настроювання параметрів синтезованих діагностичних нейромоделей.

Розроблено метод параметричної ідентифікації нейро-нечітких мереж на основі паралельного випадкового пошуку, який для настроювання параметрів синтезованих моделей (параметри функцій належності та вагові коефіцієнти нейроелементів) використовує ймовірнісну оптимізацію, початкову множину рішень формує з урахуванням інформації про навчальну вибірку (враховується значущість термів ознак, використовуючи щільність розташування екземплярів навчальної множини у відповідному термі та ступінь його впливу на значення вихідного параметра), що дозволяє наблизити початкові точки пошуку до областей розташування екстремумів і прискорити процес параметричного синтезу діагностичних нейро-нечітких моделей.

Метод донавчання діагностичних нейро-нечітких моделей, що розроблено у дисертаційній роботі, передбачає виконання етапів видобування та групування коригувальних екземплярів, діагностування за якими за допомогою існуючої моделі призводить до некоректних результатів, а також побудову коригувального блоку, який узагальнює дані коригувальних екземплярів, і впровадження його у вже існуючу модель, що дозволяє адаптувати до зміни середовища функціонування існуючі діагностичні моделі шляхом їх модифікації з урахуванням інформації, отриманої в результаті нових

спостережень. Використання запропонованого методу донавчання діагностичних нейро-нечітких моделей дозволяє не виконувати ресурсномісткий процес повторної побудови діагностичної моделі на основі повного набору даних, використовувати вже наявну модель в якості обчислювального блоку нової моделі. Крім того, моделі, синтезовані за допомогою запропонованого методу, характеризуються високою інтерпретовністю, оскільки кожен блок узагальнює інформацію про свій набір даних і в якості базису використовує нейро-нечіткі моделі.

Запропоновані критерії оцінювання інформативності ознак передбачають визначення значущості ознак, виходячи з просторового розташування екземплярів різних класів (діапазонів зміни значень вихідного параметра) та дозволяють оцінювати індивідуальну і групову інформативність ознак при розв'язанні задач діагностування в умовах, коли вихідні вибірки даних містять надлишкові і взаємозалежні ознаки, а також екземпляри з пропущеними значеннями.

Практичне значення отриманих результатів полягає у тому, що запропоновані методи оброблення діагностичних даних доведені до рівня практичної реалізації та дозволяють виконувати редукцію даних, видобування знань на основі дерев розв'язків, асоціативних правил та негативного відбору для структурного синтезу діагностичних моделей, а також будувати нейро-нечіткі діагностичні мережі, прості і зручні для подальшого аналізу та використання на практиці. Результати практичної реалізації показали, що застосування запропонованих у дисертаційній роботі методів синтезу діагностичних моделей дозволило значно підвищити швидкість побудови діагностичних моделей у порівнянні з методами, які передбачають послідовну реалізацію обчислень, збільшити рівні інтерпретовності та узагальнення даних синтезованих моделей. Розроблені методи можуть застосовуватися до

широкого кола задач діагностування, де не є відомими експертні знання про об'єкти діагностування (або природа яких є не добре вивченою), є адаптивними відносно експериментальних спостережень та можуть бути використані при синтезі діагностичних моделей на основі великих вибірок даних.

Дисертаційну роботу виконано відповідно до планів науково-дослідних робіт (НДР) Національного університету «Запорізька політехніка» в межах таких держбюджетних тем: «Інтелектуальні інформаційні технології автоматизації проектування, моделювання, керування та діагностування виробничих процесів і систем» (номер державної реєстрації – 0112U005350), «Інтелектуальні інформаційні технології діагностування та автоматичної класифікації» (номер державної реєстрації – 0115U004676), «Методи і засоби обчислювального інтелекту та паралельного комп'ютингу для оброблення великих даних в системах діагностування» (номер державної реєстрації – 0116U007419), «Методи і засоби прийняття рішень для оброблення даних в інтелектуальних системах розпізнавання образів» (номер державної реєстрації – 0117U003920), «Інтелектуальні інформаційні технології обробки даних» (номер державної реєстрації – 0118U100063), «Інтелектуальні методи та програмні засоби діагностування й неруйнівного контролю якості техніки військового та цивільного призначення» (номер державної реєстрації – 0119U100360), а також у межах госпдоговірної НДР за договором між Національним університетом «Запорізька політехніка» та Акціонерним товариством «Мотор Січ» «Аналіз прогресивних технологій моделювання, оптимізації та інтелектуальної автоматизації етапів життєвого циклу авіаційних двигунів» (номер державної реєстрації – 0110U002624). У зазначених НДР здобувач брав участь як відповідальний виконавець.

Результати роботи пройшли випробовування та впроваджені на Державному підприємстві "Запорізьке машинобудівне конструкторське бюро

"Прогрес" імені академіка О.Г. Івченка, на Лубенському верстатобудівному заводі Акціонерного товариства «Мотор Січ», на Публічному акціонерному товаристві «Запорізький металургійний комбінат «Запоріжсталь», у Запорізькому державному медичному університеті, у практичну діяльність Товариства з обмеженою відповідальністю «СофтХ», у практичну діяльність Товариства з обмеженою відповідальністю «Науково-виробниче підприємство «Енергоальянс», у практичну діяльність товариства з обмеженою відповідальністю «Дніпро-Трейд», на кафедрі програмних засобів Національного університету «Запорізька політехніка», що підтверджується відповідними актами.

Матеріали дисертації викладені у 59 публікаціях, з яких 32 наукові публікації розкривають основний зміст дисертації, зокрема опубліковано 20 статей у наукових виданнях, включених до Переліку наукових фахових видань України з технічних наук (з них 5 статей опубліковано одноосібно, 12 статей включено у міжнародні наукометричні бази Scopus та/або Web of Science), 10 статей у закордонних виданнях, проіндексованих у базах даних Scopus та/або Web of Science, 2 монографії. Опубліковано 23 тези доповідей у матеріалах міжнародних наукових конференцій (8 англійською мовою, включені в міжнародну наукометричну базу Scopus), які засвідчують апробацію матеріалів дисертації, 4 наукові праці, які додатково відображають наукові результати дисертації, зокрема 2 патенти України на винахід.

Ключові слова: діагностування, аналіз даних, нейро-нечітка модель, вибірка даних, редукція даних, синтез моделі.

СПИСОК ОПУБЛІКОВАНИХ РОБІТ ЗА ТЕМОЮ ДИСЕРТАЦІЇ

в яких опубліковані основні наукові результати дисертації:

1. Олейник, А. А. Синтез диагностических и распознающих моделей на основе гибридных нейро-нечётких технологий вычислительного интеллекта

: монографія / А. А. Олейник, Т. А. Зайко, С. А. Субботин ; под ред. С. А. Субботина. – Харьков : ООО “Компания Смит”, 2014. – 284 с.

2. Методи та засоби оброблення великих даних в системах діагностування та розпізнавання образів : монографія / [С. О. Субботін, А. О. Олійник, В. М. Льовкін, Т. О. Колпакова, М. Ю. Пришляк, С. Ю. Леоценко, О.В. Корнієнко, Д.А. Каврін, Є.О. Гофман, О.Ю. Благодарьов] ; під заг. ред. С. О. Субботіна, А. О. Олійника. – Запоріжжя : ЗНТУ, 2018. – 228 с.

3. Subbotin, S. The Dimensionality Reduction Methods Based on Computational Intelligence in Problems of Object Classification and Diagnosis / S. Subbotin, A. Oliinyk // *Recent Advances in Systems, Control and Information Technology. Advances in Intelligent Systems and Computing*. – 2017. – Vol. 543. – P. 11–19. (Входить до міжнародних наукометричних баз **Scopus** та **Web of Science**).

4. Олійник, А. О. Видобування правил на основі дерев розв’язків та стохастичного пошуку / А. О. Олійник // *Радіоелектроніка, інформатика, управління*. – 2014. – № 2. – С. 110–119. (Входить до міжнародної наукометричної бази **Web of Science**).

5. Oliinyk, A. The decision tree construction based on a stochastic search for the neuro-fuzzy network synthesis / A. Oliinyk, S. A. Subbotin // *Optical Memory and Neural Networks (Information Optics)*. – 2015. – Vol. 24, № 1. – P. 18–27. (Входить до міжнародної наукометричної бази **Scopus**).

6. Гофман, Е. А. Эволюционный метод синтеза деревьев решений / Е. А. Гофман, А. А. Олейник, С. А. Субботин // *Штучний інтелект*. – 2011. – № 2. – С. 6–14.

7. Олійник, А. О. Побудова асоціативних правил на основі інтелектуального стохастичного пошуку / А. О. Олійник // *Математичні машини і системи*. – 2015. – № 4. – С. 45–56.

8. Oliinyk, A. A stochastic approach for association rule extraction / A. Oliinyk, S. A. Subbotin // *Pattern Recognition and Image Analysis*. – 2016. –

Vol. 26, № 2. – P. 419–426. (Входить до міжнародної наукометричної бази **Scopus**).

9. Subbotin, S. Diagnostic rule mining based on artificial immune system for a case of uneven distribution of classes in sample / S. Subbotin A. Oliinyk, V. Levashenko, E. Zaitseva // Communications – Scientific Letters of the University of Zilina. – 2016. – Vol. 3. – P. 4–12. (Входить до міжнародної наукометричної бази **Scopus**).

10. Олійник, А. О. Видобування продукційних правил на основі негативного відбору / А. О. Олійник // Радіоелектроніка, інформатика, управління. – 2016. – № 1. – С. 40–49. (Входить до міжнародної наукометричної бази **Web of Science**).

11. Subbotin, S. Induction of classification rules in case of uneven distribution of classes / S. Subbotin, A. Oliinyk, V. Levashenko, E. Zaitseva // Радіоелектронні і комп'ютерні системи. – 2016. – №. 6 (80). – P. 176–180.

12. Oliinyk, A. O. Parallel Method of Production Rules Extraction Based on Computational Intelligence / A. Oliinyk, S. Skrupsky, S. Subbotin, I. Korobiichuk // Automatic Control and Computer Sciences. – 2017. – Vol. 51, Issue 4. – P. 215–223. (Входить до міжнародних наукометричних баз **Scopus** та **Web of Science**).

13. Oliinyk, A. O. Experimental research and analysis of complexity of parallel method for production rules extraction / A. Oliinyk, S. Skrupsky, S. Subbotin // Automatic Control and Computer Sciences. – 2018. – Vol. 52, Issue 2. – P. 89–99. (Входить до міжнародних наукометричних баз **Scopus** та **Web of Science**).

14. Oliinyk, A. A. The model for estimation of computer system used resources while extracting production rules based on parallel computations / A. A. Oliinyk, S. Yu. Skrupsky, V. V. Shkarupylo, S. A. Subbotin // Радіоелектроніка, інформатика, управління. – 2017. – № 1. – С. 142–152. (Входить до міжнародної наукометричної бази **Web of Science**).

15. Олейник, А. А. Мультиагентный метод оптимизации с адаптивными параметрами / А. А. Олейник // Штучний інтелект. – 2011. – № 1. – С. 83–90.

16. Олійник, А. О. Мультиагентний метод з опосередкованим зв'язком між агентами / А. О. Олійник // *Радіоелектроніка, інформатика, управління*. – 2010. – № 2. – С. 82–89. (Входить до міжнародної наукометричної бази **Web of Science**).

17. Олейник, А. А. Многомерный поиск на основе мультиагентного подхода / А. А. Олейник // *Радиоэлектроника и информатика*. – 2010. – № 2. – С. 51–55.

18. Олейник, Ан. А. Агентные технологии для отбора информативных признаков / Ан. А. Олейник, Ал. А. Олейник, С. А. Субботин // *Кибернетика и системный анализ*. – 2012. – № 2. – С. 113–125. (Входить до міжнародних наукометричних баз **Scopus** та **Web of Science**).

19. Oliinyk, A. A. Parallel multiagent method of big data reduction for pattern recognition / A. A. Oliinyk, S. Yu. Skrupsky, V. V. Shkarupylo, O. Yu. Blagodariov // *Радіоелектроніка, інформатика, управління*. – 2017. – № 2. – С. 82–92. (Входить до міжнародної наукометричної бази **Web of Science**).

20. Oliinyk, A. The System of Criteria for Feature Informativeness Estimation in Pattern Recognition / A. Oliinyk, S. Subbotin, V. Lovkin, O. Blagodariov, T. Zaiko // *Радіоелектроніка, інформатика, управління*. – 2017. – № 4. – С. 85–96. (Входить до міжнародної наукометричної бази **Web of Science**).

21. Oliinyk, A. Parallel method of big data reduction based on stochastic programming approach / A. Oliinyk, S. Subbotin, V. Lovkin, M. Pyashenko, O. Blagodariov // *Радіоелектроніка, інформатика, управління*. – 2018. – № 2. – С. 60–72. (Входить до міжнародної наукометричної бази **Web of Science**).

22. Олейник, А. А. Модель параметрического синтеза нейро-нечетких сетей в ярусно-параллельной форме / А. А. Олейник, С. Ю. Скрупский, С. А. Субботин // *Наукові праці Донецького національного технічного університету. Серія: "Інформатика, кібернетика та обчислювальна техніка"*. – 2014. – № 1 (19). – С. 106–113.

23. Oliinyk, A. O. Using Parallel Random Search to Train Fuzzy Neural Networks / A. O. Oliinyk, S. Yu. Skrupsky, S. A. Subbotin // Automatic Control and Computer Sciences. – 2014. – Vol. 48, Issue 6. – P. 313–323. (Входить до міжнародних наукометричних баз **Scopus** та **Web of Science**).

24. Oliinyk, A. A. Neural network synthesis based on evolutionary optimization / A. A. Oliinyk, S. A. Subbotin // Системні дослідження та інформаційні технології. – 2015. – № 1. – С. 77–86.

25. Oliinyk, A. O. Experimental Investigation with Analyzing the Training Method Complexity of Neuro-Fuzzy Networks Based on Parallel Random Search / A. O. Oliinyk, S. Yu. Skrupsky, S. A. Subbotin // Automatic Control and Computer Sciences. – 2015. – Vol. 49, Issue 1. – P. 11–20. (Входить до міжнародних наукометричних баз **Scopus** та **Web of Science**).

26. Олійник, А. О. Планування ресурсів паралельної обчислювальної системи при синтезі нейро-нечітких моделей для обробки великих даних / А. О. Олійник, С.Ю. Скрупський, С.О. Субботін, А.Ю. Благодарьов, Є.О. Гофман // Радіоелектроніка, інформатика, управління. – 2016. – № 4. – С. 61–69. (Входить до міжнародної наукометричної бази **Web of Science**).

27. Oliinyk, A. Additional training of neuro-fuzzy diagnostic models / A. Oliinyk, S. Subbotin, S. Leoshchenko, M. Ilyashenko, N. Myronova, Y. Mastinovskiy // Радіоелектроніка, інформатика, управління. – 2018. – № 3. – С. 106–119. (Входить до міжнародної наукометричної бази **Web of Science**).

28. Oliinyk, A. A. Information Technology of Diagnosis Model Synthesis Based on Parallel Computing / A. A. Oliinyk, S. A. Subbotin, S. Yu. Skrupsky, V. M. Lovkin, T. A. Zaiko // Радіоелектроніка, інформатика, управління. – 2017. – № 3. – С. 139–151. (Входить до міжнародної наукометричної бази **Web of Science**).

29. Гофман, Е. А. Синтез нейро-нечётких сетей на основе деревьев решений для диагностирования и автоматической классификации по признакам

/ Е. А. Гофман, С. А. Субботин, А. А. Олейник // *Радіоелектроніка та інформатика*. – 2012. – № 2. – С. 58–62.

30. Oliinyk, A. O. Factor analysis of transaction data bases / A. O. Oliinyk, T. A. Zaiko, S. A. Subbotin // *Automatic Control and Computer Sciences*. – 2014. – Vol. 48, Issue 2. – P. 87–96. (Входить до міжнародних наукометричних баз **Scopus** та **Web of Science**).

31. Олейник, А. А. Синтез нейро-нечетких сетей на основе ассоциативных правил / А. А. Олейник, Т. А. Зайко, С. А. Субботин // *Кібернетика та системний аналіз*. – 2014. – Т. 50, № 3. – С. 27–38. (Входить до міжнародних наукометричних баз **Scopus** та **Web of Science**).

32. Oliinyk, A. Training Sample Reduction Based on Association Rules for Neuro-Fuzzy Networks Synthesis / A. Oliinyk, T. Zaiko, S. Subbotin // *Optical Memory and Neural Networks (Information Optics)*. – 2014. – Vol. 23, № 2. – P. 89–95. (Входить до міжнародної наукометричної бази **Scopus**).

які засвідчують апробацію матеріалів дисертації:

33. Гофман, Е. А. Использование деревьев решений для диагностирования автотранспортных средств / Е. А. Гофман, А. А. Олейник, С. А. Субботин // *Информационные управляющие системы и компьютерный мониторинг : II Всеукраинская научно-техническая конференция ИУС и КМ-2011, Донецк, 11–13 апреля 2011 г. : материалы конференции*. – Донецк : ДонНТУ, 2011. – Т. 1. – С. 159–163.

34. Гофман, Е. А. Применение деревьев решений для редукции баз лингвистических правил / Е. А. Гофман, А. А. Олейник, С.А Субботин // *Информационные технологии и автоматизация–2011 : материалы Всеукраинской научно-производственной конференции, Одесса, 12–14 октября 2011 г. : тезисы докладов*. – Одесса : ОНАПТ, 2011. – С. 11–12.

35. Олейник, А. А. Извлечение продукционных правил на основе гибридных методов вычислительного интеллекта / А. А. Олейник // *Сучасні*

проблеми і досягнення в галузі радіотехніки, телекомунікацій та інформаційних технологій : VIII міжнародна науково-практична конференція, Запоріжжя, 21–23 вересня 2016 р. : матеріали конференції. – Запоріжжя : ЗНТУ, 2016. – С. 324–325.

36. Олійник, А. О. Редукція великих масивів даних на основі паралельного мультиагентного підходу / А. О. Олійник, С. О. Субботін // Тиждень науки : науково-практична конференція, Запоріжжя, 18–21 квітня 2017 р. : матеріали конференції. – Запоріжжя : ЗНТУ, 2017. – С. 701–703.

37. Oliinyk, A. Development of the indicator set of the features informativeness estimation for recognition and diagnostic model synthesis / A. Oliinyk, S. Subbotin, V. Lovkin, S. Leoshchenko, T. Zaiko // Advanced Trends in Radioelectronics, Telecommunications and Computer Engineering : 14th International Conference TCSET'2018, Lviv-Slavske, 20-24 February 2018 : Conference proceedings. – Lviv : Lviv Polytechnic National University, 2018. – P. 903-908. (Входить до міжнародних наукометричних баз **Scopus** та **Web of Science**).

38. Олійник, А. О. Паралельний метод видобування продукційних правил / А. О. Олійник, О. Ю. Благодарьов // Комп'ютерні інтелектуальні системи та мережі : Всеукраїнська науково-практична конференція, Кривий Ріг, 21-23 березня 2018 р. : тези доповідей. – Кривий Ріг: Видавничий центр ДВНЗ «Криворізький національний університет», 2018. – С. 157-160.

39. Oliinyk, A. Parallel data reduction method for complex technical objects and processes / A. Oliinyk, S. Leoshchenko, V. Lovkin, S. Subbotin, T. Zaiko // Dependable Systems, Services and Technologies, (DESSERT'2018) : The 9th IEEE International Conference, Kyiv, 24-27 May, 2018 : proceedings. – Los Alamitos: IEEE, 2018. – P. 496–501. (Входить до міжнародної наукометричної бази **Scopus**).

40. Oliinyk, A. Feature selection based on parallel stochastic computing / A. Oliinyk, S. Subbotin, V. Lovkin, S. Leoshchenko, T. Zaiko // Computer Science and

Information Technologies, (CSIT'2018) : XIII International Scientific and Technical Conference, Lviv, 11-14 September, 2018 : proceedings. – Lviv: Vegha i Ko, 2018. – P. 347–351. (Входить до міжнародних наукометричних баз **Scopus** та **Web of Science**).

41. Олійник, А. О. Паралельний метод синтезу нейро-нечітких мереж / А. О. Олійник // Тиждень науки : науково-практична конференція, Запоріжжя, 14–18 квітня 2014 р. : матеріали конференції. – Запоріжжя : ЗНТУ, 2014. – Т. 2. – С. 128–130.

42. Олійник, А. О. Інтелектуальна інформаційна технологія параметричного синтезу нейро-фаззі мереж / А. О. Олійник, С. О. Субботін, С. Ю. Скрупський // Інформаційні технології : I Українська конференція молодих науковців ІТ–2014, Київ, 22–23 травня 2014 р. : матеріали конференції. – Київ : Інститут суспільства Київського університету імені Бориса Грінченка, 2014. – С. 126–128.

43. Subbotin, S. The Fully-Defined Neuro-Fuzzy Model Synthesis / S. Subbotin, A. Oliinyk // Data Stream Mining & Processing (DSMP): 2016 IEEE First International Conference, Lviv, 23-27 August 2016 : proceedings. – Lviv: NU "Lvivska Politeckhnika", 2016. – P. 9-14.

44. Олійник, А. О. Дослідження процесу синтезу нейро-нечітких мереж на векторному процесорі / А. О. Олійник, С. Ю. Скрупський, С. О. Субботін // Інформаційні управляючі системи та комп'ютерний моніторинг : V Всеукраїнська науково-технічна конференція ІУС КМ-2014, Донецьк, 22–23 квітня 2014 р. : матеріали конференції. – Донецьк : ДонНТУ, 2014. – Т. 1. – С. 371–375.

45. Subbotin, S. Individual prediction of the hypertensive patient condition based on computational intelligence / S. Subbotin, A. Oliinyk, S. Skrupsky // Information and Digital Technologies : International Conference IDT'2015, Zilina, 7–9 July 2015 : proceedings of the conference. – Zilina : Institute of Electrical and

Electronics Engineers, 2015. – P. 336–344. (Входить до міжнародних наукометричних баз **Scopus** та **Web of Science**).

46. Олейник, А. А. Метод донавчання нейро-нечітких моделей / А. А. Олейник // Сучасні проблеми і досягнення в галузі радіотехніки, телекомунікацій та інформаційних технологій : IX міжнародна науково-практична конференція, Запоріжжя, 03–05 жовтня 2018 р. : матеріали конференції. – Запоріжжя : ЗНТУ, 2018. – С. 138–140.

47. Гофман, Є. О. Метод структурно-параметричного синтезу нейро-фаззи мереж / Є. О. Гофман, А. О. Олійник, С. О. Субботін // Сучасні інформаційні системи та технології : Міжнародна науково-практична конференція AIST–2012, Суми, 15–18 травня 2012 р. : матеріали конференції. – Суми : СумДУ, 2012. – С. 175–176.

48. Олейник, А. А. Выявление латентных признаков в транзакционных базах данных / А. А. Олейник, Т. А. Зайко, С. А. Субботин // Информатика та комп'ютерні технології : IX міжнародна науково-технічна конференція, Донецьк, 4–6 листопада 2013 р. : матеріали конференції. – Донецьк : ДонНТУ, 2013. – С. 233–236.

49. Олейник, А. А. Метод редукции данных для синтеза моделей неразрушающего контроля качества / А. А. Олейник, Т. А. Зайко, С. А. Субботин // Информатика: проблемы, методология, технологии : XIV Международная конференция, Воронеж, 6–8 февраля 2014 г. : материалы конференции. – Воронеж : Издательский дом Воронежского государственного университета, 2014. – Т. 3. – С. 140–144.

50. Олійник, А. О. Редукція надлишкових екземплярів в транзакційних базах даних / А. О. Олійник, Т. А. Зайко, С. О. Субботін // Сучасні інформаційні системи та технології : III міжнародна науково-практична конференція AIST-2014, Суми, 14–16 травня 2014 р. : матеріали конференції. – Суми : СумДУ, 2014. – С. 97–98.

51. Субботін, С. О. Згортальна нейронна мережа як парадигма для реалізації технології глибокого навчання / С. О. Субботін, А. О. Олійник, О. Ю. Благодарьов // Інформатика, управління та штучний інтелект : Науково-технічна конференція, Харків, 26–27 листопада 2014 р. : матеріали конференції. – Харків : НТУ «ХП», 2014. – С. 73.

52. Kolpakova, T. Improved method of group decision making in expert systems based on competitive agents selection / T. Kolpakova A. Oliinyk, V. Lovkin // 2017 IEEE First Ukraine Conference on Electrical and Computer Engineering (UKRCON), Kyiv, May 29 – June 2, 2017 : conference proceedings. – Kyiv: Institute of Electrical and Electronics Engineers, 2017. – P. 939–943. (Входить до міжнародних наукометричних баз **Scopus** та **Web of Science**).

53. Oliinyk, A. A. Evolutionary method for solving the traveling salesman problem / A. Oliinyk, I. Fedorchenko, A. Stepanenko, M. Rud, D. Goncharenko // Problems of Infocommunications. Science and Technology : 5th International Scientific-Practical Conference PICST2018, Kharkiv, 9–12 October 2018 : proceedings of the conference. – Kharkiv: Kharkiv National University of Radioelectronics, 2018. – P. 331–338. (Входить до міжнародних наукометричних баз **Scopus** та **Web of Science**).

54. Fedorchenko, I. Genetic method of image processing for motor vehicle recognition / I. Fedorchenko, A. Oliinyk, A. Stepanenko, T. Zaiko, A. Svyrydenko, D. Goncharenko [Electronic resource] // Proceedings of the Second International Workshop on Computer Modeling and Intelligent Systems (CMIS-2019), Zaporizhzhia, Ukraine, April 15-19, 2019. – P. 211-226. – (CEUR Workshop Proceedings, Vol. 2353). – Access mode: <http://ceur-ws.org/Vol-2353/paper17.pdf> . (Входить до міжнародної наукометричної бази **Scopus**).

55. Oliinyk, A. Development of Genetic Methods for Predicting the Incidence of Volumes of Emissions of Pollutants in Air / A. Oliinyk, I. Fedorchenko, A. Stepanenko, A. Katschan, Yu. Fedorchenko, A. Kharchenko, D. Goncharenko // Proceedings of the 2nd International Workshop on Informatics and Data-Driven

Medicine IDDM 2019, Lviv, 11–13 November 2019 : proceedings of the workshop. – Lviv: Lviv Polytechnic National University, 2019. – P. 340–353. – (CEUR Workshop Proceedings, Vol. 2488). (Входить до міжнародної наукометричної бази **Scopus**).

які додатково відображають наукові результати дисертації:

56. Пат. 134493 Україна, МПК G06F 17/00. Спосіб відбору інформативних ознак великих даних для побудови розпізнавальних моделей / А. О. Олійник, В. М. Льовкін, (Україна); заявник Запорізький національний технічний університет. – № u2018 10874 ; заявл. 02.11.18 ; опубл. 27.05.19, Бюл. № 10/2019.

57. Пат. 70944 Україна, МПК G06F 19/24. Спосіб побудови дерев розв'язків для виявлення знань при діагностуванні виробів / Є. О. Гофман, А. О. Олійник, С. О. Субботін, (Україна); заявник Запорізький національний технічний університет. – № u2011 15678 ; заявл. 30.12.11 ; опубл. 25.06.12, Бюл. № 12.

58. Олійник, А. О. Синтез нейро-нечітких моделей для прогнозування стану здоров'я хворого на основі паралельних обчислень / А. О. Олійник // *Радіоелектроніка, інформатика, управління.* – 2015. – № 2. – С. 30–40.

59. Oliinyk, A. Combinatorial optimization problems solving based on evolutionary approach / A. Oliinyk, I. Fedorchenko, A. Stepanenko, M. Rud, D. Goncharenko // *The experience of Designing and Application of CAD systems (CADSM): 15th International Conference CADSM'2019, Polyana (Svalyava), 26 February –2 March 2019 : proceedings of the conference.* – Lviv : Lviv Polytechnic National University, 2019. – P. 41-45. (Входить до міжнародної наукометричної бази **Scopus**).

ABSTRACT

Oliinyk A.O. Methods of diagnostic model synthesis based on computational intelligence. – Qualifying scientific work as a manuscript.

Thesis for obtaining the doctoral degree in technical sciences in the specialty 05.13.23 "Systems and means of artificial intelligence". – National University «Zaporizhzhia Polytechnic», Kharkiv National University of Radio Electronics, Ministry of Education and Science of Ukraine, Kharkiv, 2021.

The thesis is devoted to the solution of the theoretical and practical problem of the development and research of methods of diagnostic model synthesis, which combine principles of intelligent computations and parallel computing, allowing to accelerate the process of construction of diagnostic models, to raise its interpretability and generalization abilities.

The object of the research is the process of data-driven diagnosing. The subject of the research is methods of diagnostic model synthesis in intelligence systems.

Research methods: the tasks, which are set in the thesis, are solved using cluster analysis methods for detection of groups of compact observations in the synthesis of diagnostic models, theory of neuro-fuzzy networks as basis for the synthesis of diagnostic models, theory of parallel computation for the development of parallel methods of data reduction and synthesis of neuro-fuzzy diagnostic models, stochastic search and linear algebra for the development of new data processing methods based on decision trees, association rules, negative selection and neuro-fuzzy networks, methods of mathematical statistics for individual feature significance estimation in the process of construction of decision trees, extraction of association rules and synthesis of neuro-fuzzy networks, and also for analysis of efficiency of the developed methods of diagnostic model synthesis and verification of consistency of the obtained results.

The process of diagnostic model synthesis on the basis of neuro-fuzzy networks is analyzed and researched. It is determined that nowadays sets of diagnostic data are characterized by missing and contradictory values, different types of input attributes and output parameter of sampling objects, noise, unstructured nature of data, large amount of redundant data and other characteristics which significantly slow down, complicate, and in some cases make usage of the existing diagnostic data processing methods impossible. The results of the analysis concluded that such disadvantages cause the necessity of the development of new methods and data processing means which should increase the speed of information processing, as well as improve the generalization and approximation properties of diagnostic models, synthesized on the basis of existing datasets.

In the thesis stochastic method of model synthesis, based on decision trees, was proposed. It uses information about feature informativeness, complexity of synthesized tree and also about recognition accuracy, allowing to generate tree set, which is characterized by simplicity of hierarchy and by low recognition error, at the initial stage, to generate new decision sets using information about feature significance and interpretability of the generated trees during search process. In turn it allows to generate decision trees with small number of elements (nodes and connections between them) and acceptable recognition accuracy, and also to extract the most valuable observations for structural synthesis of diagnostic models.

Stochastic method of extraction of numerical association rules, which was proposed in the thesis, preliminarily defines terms based on ranges of feature values, taking into account spread width and frequency of membership of feature values to each term, applies probabilistic approach for enumeration of different combinations of antecedents and consequents of associative rules, uses prior information about significance of terms and features. Such a solution allows to process numerical information during rules extraction in the process of structural synthesis of diagnostic models, essentially reduces number of iterations for the given transaction base, finds rules with high level of probability and other criteria of its quality estimation.

The developed method of synthesis of production rules based on negative selection in the case of non-uniform distribution of instances of sampling classes generates a set of detectors based on information about observations of all sampling classes, taking into account information about individual significance of features, defines detector form as hypercube with the largest possible volume. Such a solution allows to exclude insignificant and redundant features from the sample, thus reducing the search space and time of the method realization, as well as to generate a set of detectors with high approximation and generalization properties.

The parallel method of extraction of production rules based on computational intelligence was developed. It performs parallel construction of intellectual models which summarize the given data samples in the form of models based on decision trees, associative rules, negative selection, allowing to reduce the time costs of model synthesis for solving of complex practical problems characterized by large amounts of diagnostic data, as well as problems with a need to modify existing diagnostic models when new information is obtained for objects and processes under investigation.

The parallel stochastic method of data reduction was developed. It uses different stochastic search strategies, which are based on evolutionary and multi-agent approaches and are completed on different nodes of parallel system. Such decision allows to enlarge search space, increase variety of current population decision set and reduce search time.

The model of the stochastic search representation in a tiered-parallel form for parametric synthesis of neuro-fuzzy networks was proposed. It uses a priori information about the training sample and the spatial location of solutions, which allows a more detailed investigation of the possible optima regions and reduce the time of diagnostic neuromodels training.

The method of parametric identification of neuro-fuzzy networks based on parallel random search was developed. It uses probabilistic optimization to setup the parameters of the synthesized models (parameters of the membership functions and

weight coefficients of the neuroelements), generates the initial decision based on characteristics of training set (significance of feature term based on density of distribution of training set observations in the corresponding term and range of its impact on output parameter values), allowing to bring initial search points closer to domains of extremum distribution and to speed up process of parametric synthesis of diagnostic neuro-fuzzy models.

The method of additional training of diagnostic neuro-fuzzy models was proposed in the thesis. It performs extraction and grouping of corrective observations, characterized by incorrect diagnosing results obtained by existing model, performs construction of corrective unit, which generalizes data of corrective observations, and applies it to the existing model. Such a solution allows to adopt existing diagnostic models for the changes of functioning environment by its modification through application of information which was obtained from new observations. Application of the proposed method of additional training of diagnostic neuro-fuzzy models allows to avoid resource-intensive process of repeat construction of diagnostic model using full data set, to implement the existing model as computing unit of new model. Besides models, synthesized by the proposed method, are characterized by high interpretability, because each unit generalizes information about its data set and uses neuro-fuzzy models as basis.

The proposed feature informativeness estimation criteria are based on the idea that feature significance should be computed according to spatial location of observations of different classes (size of changing of output parameter) and enable to estimate individual and group feature informativeness in diagnosis problems in situations when initial data samples contain redundant and interdependent features as well as samples with missing values.

The practical importance of the obtained results is in the proposed methods of diagnostic data processing which were practically realized and allow to perform data reduction, knowledge extraction based on decision trees, associative rules and negative selection for structural synthesis of diagnostic models, as well as to build neuro-fuzzy diagnostic networks, which are simple and convenient for the subsequent

analysis and practical usage. The results of the practical implementation showed that the application of the methods of diagnostic model synthesis allowed to significantly increase the speed of construction of diagnostic models in comparison with the methods which provide sequential computations, to increase levels of interpretability and generalization of synthesized model data. The developed methods are applicable to a wide range of diagnostic tasks where expert knowledge about the objects of diagnosis (or which nature is not fully studied) is unknown, adaptive to experimental observations and applicable for the synthesis of diagnostic models based on large data samples.

The work was performed in accordance with the plans of research works of National University «Zaporizhzhia Polytechnic» within the following state budget research works: «Intelligent Information Technologies for Design Automation, Modeling, Control and Diagnosing of Production Processes and Systems» (number of state registration 0112U005350), «Intelligent Information Technologies for Diagnosing and Automatic Classification» (number of state registration 0115U004676), «Methods and Means of Computational Intelligence and Parallel Computing for Big Data Processing in Diagnostic Systems» (number of state registration 0116U007419), «Methods and Means of Decision-Making for Data Processing in Intellectual Recognition Systems» (number of state registration 0117U003920), «Intelligent Information Technologies for Data Processing» (number of state registration 0118U100063), «Intelligent Methods and Software for Diagnosing and Non-Destructive Control of Quality of Military and Civil Equipment» (number of state registration 0119U100360), and within state order research work under the agreement between National University «Zaporizhzhia Polytechnic» and joint-stock company «Motor Sich» «Analysis of Advanced Technologies for Modeling, Optimization and Intelligent Automation of Lifecycle Phases of Aircraft Engines» (number of state registration 0110U002624). In these research works the applicant took part as the principal investigator.

The findings of the thesis have been approved and implemented in Zaporizhzhia Machine-Building Design Bureau «Progress» State Enterprise named

after Academician O.H.Ivchenko, in the Lubny Machine-Tool Plant of the joint-stock company «Motor Sich», in the Public Joint Stock Company "Zaporizhzhia Metallurgical Plant "Zaporizhstal", in Zaporizhzhia State Medical University, in the practical activity of the limited liability company «SoftX», in the practical activity of the limited liability company «Scientific production enterprise «Enerhoalians», in the practical activity of the limited liability company «Dnipro-Treid», in the Software Tools Department of National University «Zaporizhzhia Polytechnic», which is approved by the corresponding certificates.

The thesis materials are presented in 59 publications, including 32 scientific publications which reveal the main content of the thesis, particularly 20 articles are published in scientific editions, which are included into the List of Ukrainian scientific specialized editions for technical sciences (5 articles are published individually, 12 articles are published in the international scientific databases Scopus and/or Web of Science), 10 articles are published in foreign editions, indexed in the Scopus and/or Web of Science databases, 2 monographs. 23 abstracts have been published in international scientific conference materials (8 abstracts are in English, included in the Scopus international scientific base), which certify the approval of the thesis materials. 4 scientific works additionally present the scientific results of the thesis, including 2 Ukrainian patents for invention.

Keywords: diagnostics, data analysis, neuro-fuzzy model, data sample, data reduction, model synthesis.

LIST OF PUBLICATIONS

The publications which reflect the main scientific results of the thesis:

1. Олейник, А. А. Синтез диагностических и распознающих моделей на основе гибридных нейро-нечётких технологий вычислительного интеллекта : монография / А. А. Олейник, Т. А. Зайко, С. А. Субботин ; под ред. С. А. Субботина. – Харьков : ООО “Компания Смит”, 2014. – 284 с.

2. Методи та засоби оброблення великих даних в системах діагностування та розпізнавання образів : монографія / [С. О. Субботін, А. О.

Олійник, В. М. Льовкін, Т. О. Колпакова, М. Ю. Пришляк, С. Ю. Леоценко, О.В. Корнієнко, Д.А. Каврін, Є.О. Гофман, О.Ю. Благодарьов] ; під заг. ред. С. О. Субботіна, А. О. Олійника. – Запоріжжя : ЗНТУ, 2018. – 228 с.

3. Subbotin, S. The Dimensionality Reduction Methods Based on Computational Intelligence in Problems of Object Classification and Diagnosis / S. Subbotin, A. Oliinyk // *Recent Advances in Systems, Control and Information Technology. Advances in Intelligent Systems and Computing*. – 2017. – Vol. 543. – P. 11–19. (Входить до міжнародних наукометричних баз **Scopus** та **Web of Science**).

4. Олійник, А. О. Видобування правил на основі дерев розв'язків та стохастичного пошуку / А. О. Олійник // *Радіоелектроніка, інформатика, управління*. – 2014. – № 2. – С. 110–119. (Входить до міжнародної наукометричної бази **Web of Science**).

5. Oliinyk, A. The decision tree construction based on a stochastic search for the neuro-fuzzy network synthesis / A. Oliinyk, S. A. Subbotin // *Optical Memory and Neural Networks (Information Optics)*. – 2015. – Vol. 24, № 1. – P. 18–27. (Входить до міжнародної наукометричної бази **Scopus**).

6. Гофман, Е. А. Эволюционный метод синтеза деревьев решений / Е. А. Гофман, А. А. Олейник, С. А. Субботин // *Штучний інтелект*. – 2011. – № 2. – С. 6–14.

7. Олійник, А. О. Побудова асоціативних правил на основі інтелектуального стохастичного пошуку / А. О. Олійник // *Математичні машини і системи*. – 2015. – № 4. – С. 45–56.

8. Oliinyk, A. A stochastic approach for association rule extraction / A. Oliinyk, S. A. Subbotin // *Pattern Recognition and Image Analysis*. – 2016. – Vol. 26, № 2. – P. 419–426. (Входить до міжнародної наукометричної бази **Scopus**).

9. Subbotin, S. Diagnostic rule mining based on artificial immune system for a case of uneven distribution of classes in sample / S. Subbotin A. Oliinyk,

V. Levashenko, E. Zaitseva // Communications – Scientific Letters of the University of Zilina. – 2016. – Vol. 3. – P. 4–12. (Входить до міжнародної наукометричної бази **Scopus**).

10. Олійник, А. О. Видобування продукційних правил на основі негативного відбору / А. О. Олійник // Радіоелектроніка, інформатика, управління. – 2016. – № 1. – С. 40–49. (Входить до міжнародної наукометричної бази **Web of Science**).

11. Subbotin, S. Induction of classification rules in case of uneven distribution of classes / S. Subbotin, A. Oliinyk, V. Levashenko, E. Zaitseva // Радіоелектронні і комп'ютерні системи. – 2016. – №. 6 (80). – P. 176–180.

12. Oliinyk, A. O. Parallel Method of Production Rules Extraction Based on Computational Intelligence / A. Oliinyk, S. Skrupsky, S. Subbotin, I. Korobiichuk // Automatic Control and Computer Sciences. – 2017. – Vol. 51, Issue 4. – P. 215–223. (Входить до міжнародних наукометричних баз **Scopus** та **Web of Science**).

13. Oliinyk, A. O. Experimental research and analysis of complexity of parallel method for production rules extraction / A. Oliinyk, S. Skrupsky, S. Subbotin // Automatic Control and Computer Sciences. – 2018. – Vol. 52, Issue 2. – P. 89–99. (Входить до міжнародних наукометричних баз **Scopus** та **Web of Science**).

14. Oliinyk, A. A. The model for estimation of computer system used resources while extracting production rules based on parallel computations / A. A. Oliinyk, S. Yu. Skrupsky, V. V. Shkarupylo, S. A. Subbotin // Радіоелектроніка, інформатика, управління. – 2017. – № 1. – С. 142–152. (Входить до міжнародної наукометричної бази **Web of Science**).

15. Олейник, А. А. Мультиагентный метод оптимизации с адаптивными параметрами / А. А. Олейник // Штучний інтелект. – 2011. – № 1. – С. 83–90.

16. Олійник, А. О. Мультиагентний метод з опосередкованим зв'язком між агентами / А. О. Олійник // Радіоелектроніка, інформатика, управління. – 2010. – № 2. – С. 82–89. (Входить до міжнародної наукометричної бази **Web of Science**).

17. Олейник, А. А. Многомерный поиск на основе мультиагентного подхода / А. А. Олейник // Радиоэлектроника и информатика. – 2010. – № 2. – С. 51–55.
18. Олейник, Ан. А. Агентные технологии для отбора информативных признаков / Ан. А. Олейник, Ал. А. Олейник, С. А. Субботин // Кибернетика и системный анализ. – 2012. – № 2. – С. 113–125. (Входит до міжнародних наукометричних баз **Scopus** та **Web of Science**).
19. Oliinyk, A. A. Parallel multiagent method of big data reduction for pattern recognition / A. A. Oliinyk, S. Yu. Skrupsky, V. V. Shkarupylo, O. Yu. Blagodariov // Радіоелектроніка, інформатика, управління. – 2017. – № 2. – С. 82–92. (Входит до міжнародної наукометричної бази **Web of Science**).
20. Oliinyk, A. The System of Criteria for Feature Informativeness Estimation in Pattern Recognition / A. Oliinyk, S. Subbotin, V. Lovkin, O. Blagodariov, T. Zaiko // Радіоелектроніка, інформатика, управління. – 2017. – № 4. – С. 85–96. (Входит до міжнародної наукометричної бази **Web of Science**).
21. Oliinyk, A. Parallel method of big data reduction based on stochastic programming approach / A. Oliinyk, S. Subbotin, V. Lovkin, M. Pyashenko, O. Blagodariov // Радіоелектроніка, інформатика, управління. – 2018. – № 2. – С. 60–72. (Входит до міжнародної наукометричної бази **Web of Science**).
22. Олейник, А. А. Модель параметрического синтеза нейро-нечетких сетей в ярусно-параллельной форме / А. А. Олейник, С. Ю. Скрупский, С. А. Субботин // Наукові праці Донецького національного технічного університету. Серія: "Інформатика, кібернетика та обчислювальна техніка". – 2014. – № 1 (19). – С. 106–113.
23. Oliinyk, A. O. Using Parallel Random Search to Train Fuzzy Neural Networks / A. O. Oliinyk, S. Yu. Skrupsky, S. A. Subbotin // Automatic Control and Computer Sciences. – 2014. – Vol. 48, Issue 6. – P. 313–323. (Входит до міжнародних наукометричних баз **Scopus** та **Web of Science**).

24. Oliinyk, A. A. Neural network synthesis based on evolutionary optimization / A. A. Oliinyk, S. A. Subbotin // Системні дослідження та інформаційні технології. – 2015. – № 1. – С. 77–86.

25. Oliinyk, A. O. Experimental Investigation with Analyzing the Training Method Complexity of Neuro-Fuzzy Networks Based on Parallel Random Search / A. O. Oliinyk, S. Yu. Skrupsky, S. A. Subbotin // Automatic Control and Computer Sciences. – 2015. – Vol. 49, Issue 1. – P. 11–20. (Входить до міжнародних наукометричних баз **Scopus** та **Web of Science**).

26. Олійник, А. О. Планування ресурсів паралельної обчислювальної системи при синтезі нейро-нечітких моделей для обробки великих даних / А. О. Олійник, С.Ю. Скрупський, С.О. Субботін, А.Ю. Благодарьов, Є.О. Гофман // Радіоелектроніка, інформатика, управління. – 2016. – № 4. – С. 61–69. (Входить до міжнародної наукометричної бази **Web of Science**).

27. Oliinyk, A. Additional training of neuro-fuzzy diagnostic models / A. Oliinyk, S. Subbotin, S. Leoshchenko, M. Piyashenko, N. Myronova, Y. Mastinovsky // Радіоелектроніка, інформатика, управління. – 2018. – № 3. – С. 106–119. (Входить до міжнародної наукометричної бази **Web of Science**).

28. Oliinyk, A. A. Information Technology of Diagnosis Model Synthesis Based on Parallel Computing / A. A. Oliinyk, S. A. Subbotin, S. Yu. Skrupsky, V. M. Lovkin, T. A. Zaiko // Радіоелектроніка, інформатика, управління. – 2017. – № 3. – С. 139–151. (Входить до міжнародної наукометричної бази **Web of Science**).

29. Гофман, Е. А. Синтез нейро-нечётких сетей на основе деревьев решений для диагностирования и автоматической классификации по признакам / Е. А. Гофман, С. А. Субботин, А. А. Олейник // Радіоелектроніка та інформатика. – 2012. – № 2. – С. 58–62.

30. Oliinyk, A. O. Factor analysis of transaction data bases / A. O. Oliinyk, T. A. Zaiko, S. A. Subbotin // Automatic Control and Computer Sciences. – 2014. –

Vol. 48, Issue 2. – P. 87–96. (Входить до міжнародних наукометричних баз **Scopus** та **Web of Science**).

31. Олейник, А. А. Синтез нейро-нечетких сетей на основе ассоциативных правил / А. А. Олейник, Т. А. Зайко, С. А. Субботин // Кібернетика та системний аналіз. – 2014. – Т. 50, № 3. – С. 27–38. (Входить до міжнародних наукометричних баз **Scopus** та **Web of Science**).

32. Oliinyk, A. Training Sample Reduction Based on Association Rules for Neuro-Fuzzy Networks Synthesis / A. Oliinyk, T. Zaiko, S. Subbotin // Optical Memory and Neural Networks (Information Optics). – 2014. – Vol. 23, № 2. – P. 89–95. (Входить до міжнародної наукометричної бази **Scopus**).

The works that confirm the approbation of the thesis:

33. Гофман, Е. А. Использование деревьев решений для диагностирования автотранспортных средств / Е. А. Гофман, А. А. Олейник, С. А. Субботин // Информационные управляющие системы и компьютерный мониторинг : II Всеукраинская научно-техническая конференция ИУС и КМ-2011, Донецк, 11–13 апреля 2011 г. : материалы конференции. – Донецк : ДонНТУ, 2011. – Т. 1. – С. 159–163.

34. Гофман, Е. А. Применение деревьев решений для редукции баз лингвистических правил / Е. А. Гофман, А. А. Олейник, С. А. Субботин // Информационные технологии и автоматизация–2011 : материалы Всеукраинской научно-производственной конференции, Одесса, 12–14 октября 2011 р. : тезисы докладов. – Одесса : ОНАПТ, 2011. – С. 11–12.

35. Олейник, А. А. Извлечение продукционных правил на основе гибридных методов вычислительного интеллекта / А. А. Олейник // Сучасні проблеми і досягнення в галузі радіотехніки, телекомунікацій та інформаційних технологій : VIII міжнародна наукова-практична конференція, Запоріжжя, 21–23 вересня 2016 р. : матеріали конференції. – Запоріжжя : ЗНТУ, 2016. – С. 324–325.

36. Олійник, А. О. Редукція великих масивів даних на основі паралельного мультиагентного підходу / А. О. Олійник, С. О. Субботін // Тиждень науки : науково-практична конференція, Запоріжжя, 18–21 квітня 2017 р. : матеріали конференції. – Запоріжжя : ЗНТУ, 2017. – С. 701–703.

37. Oliinyk, A. Development of the indicator set of the features informativeness estimation for recognition and diagnostic model synthesis / A. Oliinyk, S. Subbotin, V. Lovkin, S. Leoshchenko, T. Zaiko // Advanced Trends in Radioelectronics, Telecommunications and Computer Engineering : 14th International Conference TCSET'2018, Lviv-Slavske, 20-24 February 2018 : Conference proceedings. – Lviv : Lviv Polytechnic National University, 2018. – P. 903-908. (Входить до міжнародних наукометричних баз **Scopus** та **Web of Science**).

38. Олійник, А. О. Паралельний метод видобування продукційних правил / А. О. Олійник, О. Ю. Благодарьов // Комп'ютерні інтелектуальні системи та мережі : Всеукраїнська науково-практична конференція, Кривий Ріг, 21-23 березня 2018 р. : тези доповідей. – Кривий Ріг: Видавничий центр ДВНЗ «Криворізький національний університет», 2018. – С. 157-160.

39. Oliinyk, A. Parallel data reduction method for complex technical objects and processes / A. Oliinyk, S. Leoshchenko, V. Lovkin, S. Subbotin, T. Zaiko // Dependable Systems, Services and Technologies, (DESSERT'2018) : The 9th IEEE International Conference, Kyiv, 24-27 May, 2018 : proceedings. – Los Alamitos: IEEE, 2018. – P. 496–501. (Входить до міжнародної наукометричної бази **Scopus**).

40. Oliinyk, A. Feature selection based on parallel stochastic computing / A. Oliinyk, S. Subbotin, V. Lovkin, S. Leoshchenko, T. Zaiko // Computer Science and Information Technologies, (CSIT'2018) : XIII International Scientific and Technical Conference, Lviv, 11-14 September, 2018 : proceedings. – Lviv: Vegha i Ko, 2018. – P. 347–351. (Входить до міжнародних наукометричних баз **Scopus** та **Web of Science**).

41. Олійник, А. О. Паралельний метод синтезу нейро-нечітких мереж / А. О. Олійник // Тиждень науки : науково-практична конференція, Запоріжжя, 14–18 квітня 2014 р. : матеріали конференції. – Запоріжжя : ЗНТУ, 2014. – Т. 2. – С. 128–130.
42. Олійник, А. О. Інтелектуальна інформаційна технологія параметричного синтезу нейро-фаззи мереж / А. О. Олійник, С. О. Субботін, С. Ю. Скрупський // Інформаційні технології : I Українська конференція молодих науковців IT–2014, Київ, 22–23 травня 2014 р. : матеріали конференції. – Київ : Інститут суспільства Київського університету імені Бориса Грінченка, 2014. – С. 126–128.
43. Subbotin, S. The Fully-Defined Neuro-Fuzzy Model Synthesis / S. Subbotin, A. Oliinyk // Data Stream Mining & Processing (DSMP): 2016 IEEE First International Conference, Lviv, 23-27 August 2016 : proceedings. – Lviv: NU "Lvivska Politeckhnika", 2016. – P. 9-14.
44. Олійник, А. О. Дослідження процесу синтезу нейро-нечітких мереж на векторному процесорі / А. О. Олійник, С. Ю. Скрупський, С. О. Субботін // Інформаційні управляючі системи та комп'ютерний моніторинг : V Всеукраїнська науково-технічна конференція ІУС КМ-2014, Донецьк, 22–23 квітня 2014 р. : матеріали конференції. – Донецьк : ДонНТУ, 2014. – Т. 1. – С. 371–375.
45. Subbotin, S. Individual prediction of the hypertensive patient condition based on computational intelligence / S. Subbotin, A. Oliinyk, S. Skrupsky // Information and Digital Technologies : International Conference IDT'2015, Zilina, 7–9 July 2015 : proceedings of the conference. – Zilina : Institute of Electrical and Electronics Engineers, 2015. – P. 336–344. (Входить до міжнародних наукометричних баз **Scopus** та **Web of Science**).
46. Олейник, А. А. Метод донавчання нейро-нечітких моделей / А. А. Олейник // Сучасні проблеми і досягнення в галузі радіотехніки, телекомунікацій та інформаційних технологій : IX міжнародна наукова-

практична конференція, Запоріжжя, 03–05 жовтня 2018 р. : матеріали конференції. – Запоріжжя : ЗНТУ, 2018. – С. 138–140.

47. Гофман, Є. О. Метод структурно-параметричного синтезу нейрофаззи мереж / Є. О. Гофман, А. О. Олійник, С. О. Субботін // Сучасні інформаційні системи та технології : Міжнародна науково-практична конференція AIST–2012, Суми, 15–18 травня 2012 р. : матеріали конференції. – Суми : СумДУ, 2012. – С. 175–176.

48. Олейник, А. А. Выявление латентных признаков в транзакционных базах данных / А. А. Олейник, Т. А. Зайко, С. А. Субботин // Информатика та комп'ютерні технології : IX міжнародна науково-технічна конференція, Донецьк, 4–6 листопада 2013 р. : матеріали конференції. – Донецьк : ДонНТУ, 2013. – С. 233–236.

49. Олейник, А. А. Метод редукции данных для синтеза моделей неразрушающего контроля качества / А. А. Олейник, Т. А. Зайко, С. А. Субботин // Информатика: проблемы, методология, технологии : XIV Международная конференция, Воронеж, 6–8 февраля 2014 г. : материалы конференции. – Воронеж : Издательский дом Воронежского государственного университета, 2014. – Т. 3. – С. 140–144.

50. Олійник, А. О. Редукція надлишкових екземплярів в транзакційних базах даних / А. О. Олійник, Т. А. Зайко, С. О. Субботін // Сучасні інформаційні системи та технології : III міжнародна науково-практична конференція AIST-2014, Суми, 14–16 травня 2014 р. : матеріали конференції. – Суми : СумДУ, 2014. – С. 97–98.

51. Субботін, С. О. Згортальна нейронна мережа як парадигма для реалізації технології глибокого навчання / С. О. Субботін, А. О. Олійник, О. Ю. Благодарьов // Информатика, управління та штучний інтелект : Науково-технічна конференція, Харків, 26–27 листопада 2014 р. : матеріали конференції. – Харків : НТУ «ХП», 2014. – С. 73.

52. Kolpakova, T. Improved method of group decision making in expert systems based on competitive agents selection / T. Kolpakova A. Oliinyk, V. Lovkin // 2017 IEEE First Ukraine Conference on Electrical and Computer Engineering (UKRCON), Kyiv, May 29 – June 2, 2017 : conference proceedings. – Kyiv: Institute of Electrical and Electronics Engineers, 2017. – P. 939–943. (Входить до міжнародних наукометричних баз **Scopus** та **Web of Science**).

53. Oliinyk, A. A. Evolutionary method for solving the traveling salesman problem / A. Oliinyk, I. Fedorchenko, A. Stepanenko, M. Rud, D. Goncharenko // Problems of Infocommunications. Science and Technology : 5th International Scientific-Practical Conference PICST2018, Kharkiv, 9–12 October 2018 : proceedings of the conference. – Kharkiv: Kharkiv National University of Radioelectronics, 2018. – P. 331–338. (Входить до міжнародних наукометричних баз **Scopus** та **Web of Science**).

54. Fedorchenko, I. Genetic method of image processing for motor vehicle recognition / I. Fedorchenko, A. Oliinyk, A. Stepanenko, T. Zaiko, A. Svyrydenko, D. Goncharenko [Electronic resource] // Proceedings of the Second International Workshop on Computer Modeling and Intelligent Systems (CMIS-2019), Zaporizhzhia, Ukraine, April 15-19, 2019. – P. 211-226. – (CEUR Workshop Proceedings, Vol. 2353). – Access mode: <http://ceur-ws.org/Vol-2353/paper17.pdf> . (Входить до міжнародної наукометричної бази **Scopus**).

55. Oliinyk, A. Development of Genetic Methods for Predicting the Incidence of Volumes of Emissions of Pollutants in Air / A. Oliinyk, I. Fedorchenko, A. Stepanenko, A. Katschan, Yu. Fedorchenko, A. Kharchenko, D. Goncharenko // Proceedings of the 2nd International Workshop on Informatics and Data-Driven Medicine IDDM 2019, Lviv, 11–13 November 2019 : proceedings of the workshop. – Lviv: Lviv Polytechnic National University, 2019. – P. 340–353. – (CEUR Workshop Proceedings, Vol. 2488).

The works that additionally reflect the scientific results of the thesis:

56. Пат. 134493 Україна, МПК G06F 17/00. Спосіб відбору інформативних ознак великих даних для побудови розпізнавальних моделей / А. О. Олійник, В. М. Льовкін, (Україна); заявник Запорізький національний технічний університет. – № u2018 10874 ; заявл. 02.11.18 ; опубл. 27.05.19, Бюл. № 10/2019.

57. Пат. 70944 Україна, МПК G06F 19/24. Спосіб побудови дерев розв'язків для виявлення знань при діагностуванні виробів / Є. О. Гофман, А. О. Олійник, С. О. Субботін, (Україна); заявник Запорізький національний технічний університет. – № u2011 15678 ; заявл. 30.12.11 ; опубл. 25.06.12, Бюл. № 12.

58. Олійник, А. О. Синтез нейро-нечітких моделей для прогнозування стану здоров'я хворого на основі паралельних обчислень / А. О. Олійник // *Радіоелектроніка, інформатика, управління.* – 2015. – № 2. – С. 30–40.

59. Oliinyk, A. Combinatorial optimization problems solving based on evolutionary approach / A. Oliinyk, I. Fedorchenko, A. Stepanenko, M. Rud, D. Goncharenko // *The experience of Designing and Application of CAD systems (CADSM): 15th International Conference CADSM'2019, Polyana (Svalyava), 26 February –2 March 2019 :*

ЗМІСТ

Перелік умовних позначень	38
Вступ.....	40
1 Огляд стану проблеми та постановка завдання дослідження.....	52
1.1 Діагностування на основі даних	52
1.2 Постановка завдання синтезу діагностичних моделей за прецедентами (спостереженнями).....	56
1.3 Властивості та характеристики вибірок вхідних даних	58
1.4 Попередня обробка даних для синтезу діагностичних моделей	65
1.5 Побудова діагностичних моделей	80
1.6 Діагностування на основі нейромережових моделей	90
1.7 Методи синтезу діагностичних моделей на основі нейро-нечітких мереж	105
1.8 Висновки за розділом 1 та постановка завдань дослідження.....	116
2 Видобування знань для побудови діагностичних моделей на основі інтелектуальних обчислень	120
2.1 Видобування знань на основі дерев розв'язків	121
2.2 Побудова асоціативних правил на основі інтелектуального стохастичного пошуку	138
2.3 Видобування продукційних правил на основі негативного відбору для випадку нерівномірного розподілу екземплярів класів вибірки	153
2.4 Висновки за розділом 2	167
3 Паралельний підхід до видобування знань при обробці великих вибірок даних для побудови діагностичних моделей.....	169
3.1 Паралельний метод видобування продукційних правил на основі обчислювального інтелекту	171

3.1.1 Застосування дерев розв'язків для видобування продукційних правил у паралельному режимі.....	171
3.1.2 Видобування продукційних правил на основі індукції асоціативних зв'язків	176
3.1.3 Виділення продукційних правил на основі негативного відбору	177
3.1.4 Модель паралельного методу видобування продукційних правил на основі обчислювального інтелекту	180
3.2 Теоретичний аналіз паралельного методу видобування продукційних правил	184
3.3 Планування ресурсів паралельної обчислювальної системи при видобуванні продукційних правил.....	192
3.4 Висновки за розділом 3	200
4 Редукція великих масивів даних.....	202
4.1 Система критеріїв оцінювання інформативності ознак для синтезу діагностичних моделей.....	202
4.2 Паралельний стохастичний метод редукції даних	212
4.3 Висновки за розділом 4	227
5 Синтез нейро-нечітких діагностичних моделей на основі паралельного стохастичного пошуку	229
5.1 Модель подання стохастичного пошуку у ярусно-паралельній формі для параметричного синтезу нейро-нечітких мереж	230
5.2 Метод параметричної ідентифікації нейро-нечітких моделей на основі паралельного випадкового пошуку	236
5.2.1 Кодування рішень	236
5.2.2 Ініціалізація.....	242
5.2.3 Оцінювання рішень.....	246
5.2.4 Розбиття поточної множини рішень на підмножини	247
5.2.5 Пошук оптимальних рішень на основі паралельного підходу	252

5.3 Аналіз обчислювальної складності й оцінювання ефективності паралельної системи	260
5.4 Висновки за розділом 5	268
6 Метод донавчання діагностичних нейро-нечітких моделей	270
6.1 Формалізація завдання донавчання діагностичних нейро-нечітких моделей.....	270
6.2 Витяг коригувальних екземплярів.....	272
6.3 Групування коригувальних екземплярів	273
6.4 Побудова коригувального блоку	277
6.5 Об'єднання наявної моделі та коригувального блоку.....	286
6.6 Висновки за розділом 6	288
7 Експериментальне дослідження методів синтезу діагностичних моделей на основі обчислювального інтелекту	290
7.1 Умови та особливості проведення експериментальних досліджень методів синтезу діагностичних моделей на основі обчислювального інтелекту.....	290
7.2 Експериментальне дослідження методів видобування продукційних правил на основі інтелектуальних обчислень	291
7.3 Експериментальне дослідження методів редукції даних.....	320
7.4 Експериментальне дослідження методів синтезу нейро-нечітких діагностичних моделей.....	329
7.5 Експериментальне дослідження методу донавчання діагностичних нейро-нечітких моделей	337
7.6 Висновки за розділом 7	345
Висновки	350
Список використаних джерел	357
Додаток А	397
Додаток Б.....	417
Додаток В	429

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ

ANFIS – Adaptive-Network-based Fuzzy Inference System – адаптивна мережева система нечіткого виведення;

CART – Classification and Regression Tree – метод побудови класифікаційних та регресійних дерев розв'язків;

FARM – Fuzzy Association Rule Mining – метод видобування асоціативних правил з використанням нечіткого підходу;

FWARM – Fuzzy Weighted Association Rule Mining – метод видобування зважених асоціативних правил з використанням нечіткого підходу;

IGA – Island Genetic Algorithm – острівна модель еволюційного пошуку;

LSTM – Long short-term memory – довга короткочасна пам'ять;

АП – асоціативне правило;

КМЕП – канонічний метод еволюційного пошуку;

МАГК – метод аналізу головних компонент;

МГВА – метод групового врахування аргументів;

МДННМ – метод донавчання нейро-нечітких моделей;

МЗП – метод зворотного поширення помилки;

ММНЗА – мультиагентний метод відбору інформативних ознак з непрямим зв'язком між агентами;

ММПЗА – мультиагентний метод відбору інформативних ознак з прямим зв'язком між агентами;

МПДВО – метод почергового додавання і видалення ознак;

МСАПВЗО – метод синтезу асоціативних правил з врахуванням значущості ознак;

МСППОНВ – метод синтезу продукційних правил на основі негативного відбору;

НДР – науково-дослідна робота;

ННМ – нейро-нечітка мережа;

ПМВПП – паралельний метод видобування продукційних правил;

ПМРВД – паралельний метод редукції великих даних;

ПМПННМ – паралельний метод параметричної ідентифікації нейро-нечітких моделей.

ВСТУП

Обґрунтування вибору теми дослідження. Розроблення систем технічного та біомедичного діагностування пов'язано з необхідністю аналізу та оброблення інформації, обсяг якої постійно збільшується. Це обумовлено зростанням апаратних можливостей комп'ютерної техніки щодо збору та зберігання інформації, а також отриманням нової інформації про досліджувані об'єкти чи процеси. Для побудови систем діагностування потрібно мати відповідну діагностичну модель. У більшості випадків на практиці об'єкти діагностування є багатовимірними, нелінійними та не повністю дослідженими (теоретичні та експертні знання про об'єкти діагностування є неповними або відсутніми). Діагностування на основі даних є універсальним механізмом побудови діагностичних моделей у випадках, коли відсутні аналітичні описи об'єктів діагностування.

Методи обчислювального інтелекту (зокрема, нейро-нечіткі та еволюційні) є перспективним базисом для створення діагностичних моделей при розробці інтелектуальних систем діагностування, керованих даними. Проте відомі методи обчислювального інтелекту характеризуються значними витратами часу при послідовній реалізації обчислень, що суттєво обмежує їхнє застосування на практиці, особливо для задач великої розмірності. Синтезовані за допомогою таких методів діагностичні моделі, як правило, мають надмірну структуру та велику кількість параметрів, що у свою чергу призводить до низького рівня узагальнення даних, зменшення рівня зрозумілості моделі для людини (інтерпретовності моделі), а також значних витрат пам'яті. Це суттєво обмежує застосування відомих методів штучного інтелекту на практиці, особливо при розв'язанні задач великої розмірності. Крім того, у зв'язку з появою нових даних про досліджувані об'єкти виникає потреба переналаштування параметрів вже побудованої діагностичної моделі без

повторного виконання складних процедур її синтезу за всім набором наявних даних.

Тому виникає потреба у розробленні методів побудови діагностичних моделей на основі інтелектуальних обчислень, що дозволять прискорити процес побудови моделей об'єктів діагностування, підвищити їх інтерпретовність та узагальнювальні можливості.

Значний внесок у розвиток обчислювального інтелекту, зокрема штучних нейронних і нейро-нечітких мереж та еволюційних обчислень, внесли Ф. Розенблатт, П. Вербос, Б. Уїдроу, Д. Хопфілд, Д. Румельхарт, Л. Заде, Е. Мамдані, Т. Сугено, Д. Голланд, О.Г. Івахненко, Є.В. Бодянський, О.Г. Руденко, М.М. Корабльов, Ю.П. Зайченко, Н.М. Куссуль, В. І. Литвиненко, Ю.О.Скобцов, В.С. Степашко, В.Д. Дмитрієнко, С.Ю. Леонов та ін.

Таким чином, актуальною є науково-прикладна проблема розроблення та дослідження методів синтезу діагностичних моделей, які поєднують принципи інтелектуальних та паралельних обчислень, що дозволяє підвищити швидкість процесу побудови діагностичних моделей, збільшити їх інтерпретовність та узагальнювальні можливості.

Зв'язок роботи з науковими програмами, планами, темами.
Дисертаційна робота виконана відповідно до планів науково-дослідних робіт (НДР) Національного університету «Запорізька політехніка» у межах таких держбюджетних тем: «Інтелектуальні інформаційні технології автоматизації проектування, моделювання, керування та діагностування виробничих процесів і систем» (номер державної реєстрації – 0112U005350), «Інтелектуальні інформаційні технології діагностування та автоматичної класифікації» (номер державної реєстрації – 0115U004676), «Методи і засоби обчислювального інтелекту та паралельного комп'ютингу для оброблення великих даних в системах діагностування» (номер державної реєстрації – 0116U007419), «Методи і засоби прийняття рішень для оброблення даних в інтелектуальних системах розпізнавання образів» (номер державної реєстрації –

0117U003920), «Інтелектуальні інформаційні технології обробки даних» (номер державної реєстрації – 0118U100063), «Інтелектуальні методи та програмні засоби діагностування й неруйнівного контролю якості техніки військового та цивільного призначення» (номер державної реєстрації – 0119U100360), а також у межах госпдоговірної НДР за договором між Національним університетом «Запорізька політехніка» та Акціонерним товариством «Мотор Січ» «Аналіз прогресивних технологій моделювання, оптимізації та інтелектуальної автоматизації етапів життєвого циклу авіаційних двигунів» (номер державної реєстрації – 0110U002624). У зазначених НДР здобувач брав участь як відповідальний виконавець, удосконалив та розробив методи оброблення даних для синтезу діагностичних моделей на основі нейро-нечітких мереж та стохастичного пошуку.

Мета та завдання дослідження. Метою дисертаційної роботи є розроблення та дослідження методів високопродуктивного оброблення даних для синтезу діагностичних моделей, які поєднують інтелектуальні та паралельні обчислення для підвищення швидкості процесу побудови діагностичних моделей, збільшення їх інтерпретовності та узагальнювальних можливостей.

Для досягнення поставленої мети необхідно розв'язати такі задачі:

- виконати аналіз та дослідження процесу синтезу діагностичних моделей на основі нейро-нечітких мереж;
- розробити нові методи видобування продукційних правил на основі дерев розв'язків, негативного відбору та асоціативних правил для синтезу діагностичних моделей;
- розробити паралельний метод видобування знань при обробці великих вибірок даних;
- розробити систему критеріїв оцінювання індивідуальної та групової інформативності ознак;
- розробити метод редукції даних на основі стохастичного підходу та високопродуктивних обчислень;
- розробити метод синтезу нейро-нечітких діагностичних моделей;

- розробити метод донавчання діагностичних нейро-нечітких моделей;
- провести експериментальне дослідження розроблених методів обробки даних та синтезу діагностичних моделей.

Об’єкт дослідження – процес діагностування на основі даних.

Предмет дослідження – методи синтезу моделей в інтелектуальних системах діагностування.

Методи дослідження. Для вирішення завдань, поставлених у дисертаційній роботі, використано методи: кластерного аналізу – для виявлення груп компактно розташованих екземплярів при синтезі діагностичних моделей; теорії нейро-нечітких мереж – як базис для синтезу діагностичних моделей; теорії паралельних обчислень – для розробки паралельних методів редукції даних та синтезу нейро-нечітких діагностичних моделей; стохастичного пошуку та лінійної алгебри для створення нових методів оброблення даних на основі дерев розв’язків, асоціативних правил, негативного відбору та нейро-нечітких мереж; математичної статистики – для обчислення оцінок індивідуальної значущості ознак в процесі побудови дерев розв’язків, видобування асоціативних правил та синтезу нейро-нечітких мереж, а також для аналізу ефективності розроблених методів синтезу діагностичних моделей та перевірки достовірності отриманих результатів.

Наукова новизна отриманих результатів. Основні результати, які визначають наукову новизну роботи, полягають у такому.

Вперше запропоновано метод синтезу продукційних правил на основі негативного відбору для випадку нерівномірного розподілу екземплярів класів вибірки, який при генерації набору детекторів використовує відому інформацію про екземпляри всіх класів вибірки, враховує інформацію про індивідуальну значущість ознак, що дозволяє виключати малозначущі та надлишкові ознаки з вибірки, скоротивши тим самим простір пошуку і час виконання методу, а також формувати набір детекторів з високими апроксимаційними й узагальнювальними властивостями.

Вперше запропоновано паралельний метод видобування продукційних правил на основі обчислювального інтелекту, що здійснює паралельну побудову інтелектуальних моделей, які узагальнюють задані вибірки даних у вигляді моделей на основі дерев розв'язків, асоціативних правил, негативного відбору, що дозволяє скоротити часові витрати на синтез моделей при обробленні великих обсягів діагностичних даних.

Вперше запропоновано паралельний стохастичний метод редукції даних, в якому використовуються різні стратегії інтелектуального пошуку та виконується оцінювання концентрованості контрольних точок навколо локальних екстремумів, що дозволяє розширити покриття простору пошуку, зменшити надмірну концентрацію рішень в областях локальних оптимумів для підвищення рівномірності пошуку, скоротити час пошуку, і, як наслідок, збільшити практичний поріг застосовуваності методів відбору ознак при обробці великих обсягів даних.

Вперше запропоновано метод параметричної ідентифікації нейро-нечітких мереж на основі паралельного стохастичного пошуку, в якому початкова множина рішень формується з урахуванням апріорної інформації про навчальну вибірку, з метою більш детального дослідження областей локальних оптимумів виконується розбиття поточної множини рішень на підмножини з урахуванням інформації про просторове розташування рішень, з наступним пошуком оптимумів у кожній з них на відповідних процесах паралельної системи, обчислювально складні етапи пошуку виконуються на різних вузлах паралельної системи, оператори формування нової множини рішень враховують особливості параметрів, що налаштовуються, що дозволяє наблизити початкові точки пошуку до областей розташування екстремумів, виходити з можливих областей локальних екстремумів та прискорити процес параметричного синтезу діагностичних нейро-нечітких моделей.

Вперше запропоновано метод донавчання діагностичних нейро-нечітких моделей, у якому виконується побудова коригувального блоку, що узагальнює

дані коригувальних екземплярів, і впровадження його у вже існуючу модель, що дозволяє модифікувати діагностичні моделі з урахуванням інформації, отриманої в результаті нових спостережень.

Удосконалено стохастичний метод синтезу моделей на основі дерев розв'язків, який відрізняється використанням інформації про інформативність ознак, складність синтезованого дерева, точність його розпізнавання, що дозволяє на початковому етапі формувати множину деревоподібних структур, які характеризуються простою ієрархією та невисокою помилкою розпізнавання, у процесі пошуку створювати нові множини розв'язків з урахуванням інформації про значущість ознак та інтерпретовність генерованих дерев, що, у свою чергу, забезпечує можливість побудови дерева розв'язків з невеликою кількістю вузлів і зв'язків між ними та прийнятною точністю розпізнавання, а також можливість видобування на його основі найцінніших екземплярів для структурного синтезу діагностичних моделей.

Удосконалено стохастичний метод видобування чисельних асоціативних правил, який відрізняється попереднім розбиттям значень ознак на інтервали, використовує ймовірнісний перебір сполучень антецедентів і консеквентів асоціативних правил та апріорну інформацію про значущість термів й ознак, що дозволяє істотно скоротити кількість проходів по заданому набору даних, виявляти правила з високим рівнем вірогідності й інших критеріїв оцінювання їхньої якості.

Удосконалено модель подання стохастичного пошуку у ярусно-паралельній формі для параметричного синтезу нейро-нечітких мереж, яка відрізняється використанням апріорної інформації про навчальну вибірку та просторове розташування рішень, що дозволяє більш детально досліджувати області можливих оптимумів та скоротити час настроювання параметрів синтезованих діагностичних нейромоделей.

Удосконалено систему критеріїв оцінювання інформативності ознак, яка відрізняється можливістю визначення значущості ознак, виходячи з

просторового розташування екземплярів різних класів, та не вимагає побудови моделей на основі оцінюваних комбінацій ознак, що істотно знижує часові й обчислювальні витрати в процесі відбору інформативних ознак.

Практичне значення отриманих результатів полягає у тому, що запропоновані методи оброблення діагностичних даних доведені до рівня практичної реалізації та дозволяють виконувати редукцію даних, видобування знань на основі дерев розв'язків, асоціативних правил та негативного відбору для структурного синтезу діагностичних моделей, а також будувати нейро-нечіткі діагностичні мережі, прості і зручні для подальшого аналізу та використання на практиці.

Результати практичної реалізації показали, що застосування запропонованих у дисертаційній роботі методів синтезу діагностичних моделей дозволило значно підвищити швидкість побудови діагностичних моделей (у два та більше разів) у порівнянні з методами, які передбачають послідовну реалізацію обчислень, збільшити рівні інтерпретовності та узагальнення даних синтезованих моделей (на 20–40 %). Розроблені методи можуть застосовуватися до широкого кола задач діагностування, де є невідомими експертні знання про об'єкти діагностування (або природа яких є недостатньо вивченою), є адаптивними відносно експериментальних спостережень та можуть бути використані при синтезі діагностичних моделей на основі великих вибірок даних. Розроблені методи синтезу діагностичних моделей на основі нейро-нечітких мереж можуть знайти широке застосування та практичне використання при створенні інтелектуальних систем діагностування у різних галузях економіки, зокрема у авіадвигунобудуванні, військовій промисловості, приладобудуванні, медицині тощо.

Наукові положення, висновки і рекомендації, викладені в дисертаційній роботі, використано при підготовці дисциплін «Інтелектуальні системи», «Основи обчислювального інтелекту», «Еволюційне моделювання» на кафедрі

програмних засобів Національного університету «Запорізька політехніка» (акт впровадження від 05.03.20).

Результати дисертаційної роботи апробовано та впроваджено на Державному підприємстві «Запорізьке машинобудівне конструкторське бюро «Прогрес» імені академіка О.Г. Івченка (акт впровадження від 27.02.2020), на Лубенському верстатобудівному заводі Акціонерного товариства «Мотор Січ» (акт впровадження від 10.03.2020), на Публічному акціонерному товаристві «Запорізький металургійний комбінат «Запоріжсталь» (акт впровадження від 28.01.2020), у Запорізькому державному медичному університеті (акт впровадження від 2.03.2020), у практичну діяльність Товариства з обмеженою відповідальністю «СофтХ» (акт впровадження від 20.02.2020), у практичну діяльність Товариства з обмеженою відповідальністю «Науково-виробниче підприємство «Енергоальянс» (акт впровадження від 14.04.2016), у практичну діяльність товариства з обмеженою відповідальністю «Дніпро-Трейд» (акт впровадження від 15.06.2020), де використовуються для побудови діагностичних моделей технічних та медичних об'єктів.

Особистий внесок здобувача. Всі основні наукові результати дисертаційної роботи отримано автором особисто. Роботу з експериментального дослідження програмних модулів, що реалізують запропоновані у роботі методи синтезу діагностичних моделей, проведено разом із співавторами, прізвища яких наведено у бібліографічному списку. У роботах, написаних зі співавторами, здобувачеві належать такі результати: [1] – метод синтезу нейро-нечітких мереж на основі паралельного випадкового пошуку; [2] – паралельний стохастичний метод редукції даних; [3] – аналіз методів редукції даних для розв'язання завдань діагностування; [5] – стохастичний метод синтезу дерев розв'язків; [6] – дослідження ефективності використання еволюційного підходу для синтезу дерев розв'язків; [8] – стохастичний метод видобування чисельних асоціативних правил; [9] – метод видобування діагностичних правил для випадку нерівномірного розподілу

екземплярів по класам навчальної вибірки; [11] – розробка методу синтезу продукційних правил на основі негативного відбору; [12] – паралельний метод видобування продукційних правил на основі обчислювального інтелекту; [13] – експериментальне дослідження паралельного методу видобування продукційних правил; [14] – модель планування ресурсів паралельної обчислювальної системи при видобуванні продукційних правил; [18] – дослідження ефективності використання мультиагентного підходу для відбору інформативних ознак; [19] – паралельний мультиагентний метод редукції великих масивів даних; [20] – система критеріїв оцінювання інформативності ознак; [21] – розробка паралельного методу редукції даних на основі стохастичного підходу; [22] – модель процесу параметричного синтезу нейро-нечітких мереж у ярусно-паралельній формі; [23] – аналіз доцільності використання паралельного випадкового пошуку для навчання нейро-нечітких мереж; [24] – розробка методу синтезу діагностичних нейромоделей на основі еволюційної оптимізації; [25] – експериментальне дослідження методу синтезу нейро-нечітких мереж на основі паралельного випадкового пошуку; [26] – синтез моделі планування ресурсів паралельної обчислювальної системи при побудові нейро-нечітких мереж; [27] – метод донавчання діагностичних нейро-нечітких моделей; [28] – технологія синтезу діагностичних моделей на основі паралельних обчислень; [29] – обґрунтування доцільності застосування дерев розв’язків для структурного синтезу нейро-нечітких мереж; [30] – дослідження процесу редукції даних з використанням асоціативних правил; [31] – обґрунтування доцільності застосування асоціативних правил для структурного синтезу нейро-нечітких моделей; [32] – дослідження методу редукції даних для синтезу нейро-нечітких мереж; [33] – аналітичний огляд процесу застосування дерев розв’язків для технічного діагностування; [34] – обґрунтування доцільності застосування дерев розв’язків для редукції даних; [36] – паралельний мультиагентний підхід для редукції великих масивів даних; [37] – розробка та дослідження критеріїв оцінювання інформативності ознак для

синтезу діагностичних моделей; [38] – паралельний підхід до видобування продукційних правил; [39] – дослідження паралельного методу редукції даних для технічного діагностування; [40] – обґрунтування доцільності застосування паралельного стохастичного пошуку для відбору ознак; [42] – дослідження технології параметричного синтезу нейро-фаззі мереж; [43] – аналітичний огляд процесу синтезу нейро-нечітких моделей; [44] – експериментальне дослідження процесу синтезу нейро-нечітких мереж на векторному процесорі; [45] – вирішення задачі медичного діагностування на основі обчислювального інтелекту; [47] – дослідження ефективності застосування дерев розв’язків для синтезу нейро-нечітких діагностичних моделей; [48] – процедура виділення термів ознак для скорочення навчальних вибірок даних; [49] – дослідження процесу редукції даних для синтезу діагностичних моделей; [50] – обґрунтування доцільності редукції даних на основі асоціативних правил; [51] – аналітичний огляд моделей на основі нейронних мереж; [52] – дослідження процесу прийняття рішень на основі інтелектуальних технологій; [53] – модифікація процесу стохастичного пошуку на основі еволюційних обчислень; [54] – експериментальне дослідження методу генетичного пошуку; [55] – синтез діагностичних моделей на основі інтелектуальних обчислень; [56] – розробка способу відбору інформативних ознак великих даних; [57] – розв’язання завдання технічного діагностування на основі дерев розв’язків; [59] – модифікація генетичних операторів у стохастичному методі еволюційного пошуку.

Апробація матеріалів дисертації. Основні результати дисертаційної роботи доповідалися й обговорювалися на міжнародних конференціях і форумах: International Conference “Information and Digital Technologies (IDT’2015)”, 7–9 July 2015 (Zilina, Slovak Republic); IEEE First International Conference “Data Stream Mining & Processing (DSMP)”, 23-27 August 2016 (Lviv); 14th International Conference “Advanced Trends in Radioelectronics, Telecommunications and Computer Engineering (TCSET’2018)”, 20-24 February

2018 (Lviv); 9th IEEE International Conference “Dependable Systems, Services and Technologies (DESSERT’2018)”, 24-27 May, 2018 (Kyiv); XIIIth International Scientific and Technical Conference “Computer Science and Information Technologies (CSIT’2018)”, 11-14 September, 2018 (Lviv); IEEE First Ukraine Conference “Electrical and Computer Engineering (UKRCON)”, May 29 – June 2, 2017 (Kyiv); 5th International Scientific-Practical Conference “Problems of Infocommunications. Science and Technology (PICST2018)”, 9–12 October 2018 (Kharkiv); 2nd International Workshop “Computer Modeling and Intelligent Systems (CMIS-2019)”, 15-19 April, 2019 (Zaporizhzhia); 2nd International Workshop “Informatics and Data-Driven Medicine (IDDM 2019)”, 11–13 November 2019 (Lviv); IV Всеукраїнська науково-практична конференція «Інформаційні технології та автоматизація», 12-14 жовтня 2011 р. (Одеса); II та V Всеукраїнська науково-технічна конференція «Інформаційні управляючі системи та комп’ютерний моніторинг (IYC KM)», 11-13 квітня 2011 р., 22–23 квітня 2014 р. (Донецьк); I та III Міжнародна науково-практична конференція «Сучасні інформаційні системи та технології (AIST)», 15–18 травня 2012 р., 14–16 травня 2014 р. (Суми); IX Міжнародна науково-технічна конференція «Інформатика та комп’ютерні технології», 4-6 листопада 2013 р. (Донецьк); XIV Міжнародна конференція «Інформатика: проблеми, методологія, технології», 6-8 лютого 2014 р. (Воронеж); Науково-технічна конференція «Інформатика, управління та штучний інтелект», 26–27 листопада 2014 р. (Харків); I Українська конференція «Інформаційні технології (IT–2014)», 22–23 травня 2014 р. (Київ); Науково-практична конференція «Тиждень науки», 14–18 квітня 2014 р., 18–21 квітня 2017 р. (Запоріжжя); VIII та IX Міжнародна науково-практична конференція «Сучасні проблеми і досягнення в галузі радіотехніки, телекомунікацій та інформаційних технологій», 21–23 вересня 2016 р., 03–05 жовтня 2018 р. (Запоріжжя); Всеукраїнська науково-практична конференція «Комп’ютерні інтелектуальні системи та мережі», 21-23 березня 2018 р. (Кривий Ріг).

Матеріали дисертації повною мірою викладені у 59 публікаціях, з яких 32 наукові публікації розкривають основний зміст дисертації, зокрема опубліковано 20 статей у наукових виданнях, включених до Переліку наукових фахових видань України з технічних наук (з них 5 статей опубліковано одноосібно, 12 статей включено у міжнародні наукометричні бази Scopus та/або Web of Science), 10 статей у закордонних виданнях, проіндексованих у базах даних Scopus та/або Web of Science, 2 монографії. Опубліковано 23 тези доповідей у матеріалах міжнародних наукових конференцій (8 англійською мовою, включені в міжнародну наукометричну базу Scopus), які засвідчують апробацію матеріалів дисертації, 4 наукові праці, які додатково відображають наукові результати дисертації, зокрема 2 патенти України на винахід.

Структура та обсяг дисертації. Дисертація складається зі вступу, 7 розділів, висновків, списку використаних джерел, додатків. Загальний обсяг роботи складає 439 сторінок тексту, що містять 2 анотації на 33 сторінках, 37 рисунків, 20 таблиць, список використаних джерел з 352 найменувань на 40 сторінках, 3 додатки на 43 сторінках.

1 ОГЛЯД СТАНУ ПРОБЛЕМИ ТА ПОСТАНОВА ЗАВДАННЯ ДОСЛІДЖЕННЯ

З метою забезпечення надійної та безпечної експлуатації складних об'єктів, підвищення якості продукції, своєчасного виявлення дефектів та помилок у роботі технічних та медичних систем широкого використання набули інтелектуальні системи діагностування, розроблення яких пов'язано з необхідністю обробки множин великих даних та синтезу діагностичних моделей [1–7].

Розділ присвячено аналізу стану проблеми діагностування на основі даних. За для цього аналізуються властивості та характеристики вибірок вхідних даних для синтезу діагностичних моделей, розглядаються методи попередньої обробки діагностичних даних та різні види моделей, які можуть використовуватись як базис для синтезу моделей об'єктів діагностування, досліджуються методи синтезу діагностичних моделей на основі нейро-нечітких мереж.

1.1 Діагностування на основі даних

Для визначення та прогнозування стану об'єктів і процесів з метою попередження їхнього передчасного виходу з ладу, пошуку некондиційних виробів, виявлення дефектів і несправностей на ранніх стадіях широко застосовуються методи технічного діагностування [1–4, 8–22]. Такі методи дозволяють визначити технічний стан об'єктів [23–25] і, відповідно, істотно скоротити кількість бракованих виробів, поліпшити якість продукції,

підвищити значення показників надійності та безпечної експлуатації складних технічних об'єктів і систем [1–3, 7, 17, 23, 26].

Завдання діагностування може бути подане як завдання класифікації (розпізнавання), коли на основі спостережень за об'єктом діагностування необхідно співвіднести його з певним класом [27, 28].

Для розв'язання завдань діагностування використовуються різні методи [1–11, 29–35], які можна класифікувати на фізичні методи (physics-based) діагностування, методи діагностування, засновані на моделях, (model-based) і методи діагностування на основі даних (data-based, data-driven methods) [1, 2, 29]. Фізичні методи та методи діагностування на основі моделей іноді об'єднують в групу методів на основі експертних знань [2, 27–29, 36], оскільки такі методи використовують уявлення і накопичені знання експертів про об'єкти діагностування.

При використанні фізичних (інструментальних) методів за допомогою спеціальних підходів (магнітних, електричних, хімічних, оптичних, радіаційних і т.ін.) виконується дослідження об'єкту діагностування з метою встановлення його стану. До таких методів відносять методи неруйнівного контролю (візуальний огляд, ультразвукові методи, аналіз вібрацій, перевірка зовнішньої герметичності об'єкта, термографія і т.ін.) і методи деформаційного впливу (методи, які передбачають деякий вплив, що може привести до деформації або руйнування об'єкту діагностування з допомогою, наприклад, акустичної емісії або спеціально організованого силового, ударного, температурного збудження) [2, 27–29, 37–40]. Проте ефективність застосування таких методів суттєво залежить від фахівців, задіяних в процесі діагностування. Іншими недоліками фізичних методів діагностування є відносно висока складність і трудомісткість такого процесу, його висока вартість і великі часові витрати, що обумовлено залученням до процесу діагностування, як правило, великої кількості персоналу.

Методи діагностування, засновані на моделях (Model-based), використовують математичне подання (опис) системи, засноване на апріорних

знаннях про природні (фізичні, медичні, біологічні) закони [1, 2, 28, 29, 33]. Такі методи забезпечують дуже високу точність діагностування, однак така точність може бути забезпечена тільки у випадку застосування аналітичної моделі, яка детально і достовірно описує об'єкти, що діагностуються [1, 2, 28, 34–37]. Діагностовані об'єкти і системи, як правило, є досить складними і часто не зовсім вивченими та дослідженими, а значить, відсутні їх повні описи (математичні моделі, засновані на фізичних або інших законах природи), що часто унеможлиблює використання діагностування, заснованого на моделях [2, 28, 29, 33]. Крім того, часто діагностовані об'єкти або системи можуть змінюватися з часом в залежності від факторів, не врахованих в діагностичній моделі, що також ускладнює використання методів діагностування, заснованих на моделях (наприклад, в медичному діагностуванні пацієнт може отримати нову хворобу, що ускладнить прогнозування його стану за наявною моделлю) [1, 28, 29, 41]. Тому область застосування методів діагностування, заснованих на моделях, як правило, обмежена лише досконально вивченими та дослідженими об'єктами і процесами.

Набори даних, зібрані за допомогою методів на основі знань (фізичних методів діагностування та методів, заснованих на моделях), можуть бути ефективно використані при застосуванні методів діагностування на основі даних (Data-based diagnosis approaches, Data-Driven Methods for Fault Detection and Diagnosis) [2, 4, 6, 7, 20, 27, 30–33, 37, 42, 43]. Такі методи, передбачають використання доступних даних, отриманих раніше, наприклад, з різних датчиків, встановлених на діагностованих об'єктах, як правило, не вимагають проведення фізичних досліджень над об'єктом діагностування, не вимагають розуміння механізму виникнення несправності у діагностованому об'єкті та суттєво знижують роль людини в процесі діагностування. Варто відзначити, що об'єкт, стан якого визначається (об'єкт діагностування) за допомогою методів діагностування на основі даних, може бути як технічним (наприклад, деякий виріб), так і медичним (людина), оскільки такі методи можуть ефективно

застосовуватися для розв'язання завдань як технічного, так і медичного діагностування.

Методи діагностування на основі даних співвідносять виміряні вхідні і вихідні дані про діагностовані об'єкти, як правило, за допомогою технологій аналізу даних, розпізнавання образів, синтезу математичних моделей [44–62]. В залежності від вхідних даних для діагностування можуть використовуватися методи обробки сигналів і управління, а також методи штучного інтелекту для синтезу діагностичних моделей на основі дерев розв'язків, множин експертних правил, нейронних мереж, нечіткої логіки і т. ін. [63–87]. Такі методи, як правило, не потребують будь-якої експертної інформації про досліджувані об'єкти, не вимагають наявності відомих функціональних залежностей між вхідними та вихідними параметрами (формул і моделей, побудованих на основі фізичних законів) [44–97]. Замість цього вхідною інформацією для таких методів є лише набори даних, що містять інформацію про значення вхідних атрибутів для деяких об'єктів і відповідні значення вихідних параметрів. Таким чином, відсутність вимог до наявності експертної інформації та апріорно відомих аналітичних моделей, що детально і достовірно описують діагностовані об'єкти, дозволяє обрати методи, засновані на даних, як базис для вирішення завдань технічного та медичного діагностування.

Однак моделі, синтезовані за допомогою методів діагностування на основі на даних, як правило, є більш складними і менш зрозумілими в порівнянні з фізичними моделями. Відповідно, моделі, синтезовані за наборами спостережень за діагностованими об'єктами, мають низьку інтерпретовність, що ускладнює розуміння процесу прийняття рішень за такими моделями [1–7, 27, 30–33, 37, 42–102] і обумовлює необхідність розробки нових методів, що дозволяють синтезувати діагностичні моделі, які є більш доступними для розуміння і забезпечують високі показники точності діагностування.

1.2 Постановка завдання синтезу діагностичних моделей за прецедентами (спостереженнями)

Нехай задано множину спостережень S (1.1):

$$S = \langle P, T \rangle, \quad (1.1)$$

де P – набір атрибутів (діагностичних параметрів, ознак характеристик) спостережень за об'єктами діагностування;

T – множина значень вихідного параметра об'єктів діагностування.

Набори значень P і T можуть бути подані у вигляді матриці (1.2) і вектора (1.3), відповідно:

$$P = \begin{pmatrix} p_{11} & p_{12} & \dots & p_{1m} & \dots & p_{1M} \\ p_{21} & p_{22} & \dots & p_{2m} & \dots & p_{2M} \\ \dots & \dots & \dots & \dots & \dots & \dots \\ p_{q1} & p_{q2} & \dots & p_{qm} & \dots & p_{qM} \\ \dots & \dots & \dots & \dots & \dots & \dots \\ p_{Q1} & p_{Q2} & \dots & p_{Qm} & \dots & p_{QM} \end{pmatrix}, \quad (1.2)$$

$$T = (t_1 \ t_2 \ \dots \ t_q \ \dots \ t_Q)^{\text{tr}}, \quad (1.3)$$

де p_{qm} – значення m -го атрибуту q -го спостереження ($m = 1, 2, \dots, M$, $q = 1, 2, \dots, Q$);

t_q – значення вихідного параметра q -го спостереження;

M – кількість атрибутів;

Q – кількість спостережень;

tr – знак операції транспонування.

Таким чином, вхідною інформацією для синтезу діагностичних моделей є вибірка даних $S = \langle P, T \rangle$, що містить інформацію про множину досліджуваних об'єктів. Кожен екземпляр s_q вибірки S характеризується значеннями p_{qm} ознак p_m , що описують особливості об'єктів даних.

Завдання синтезу моделі прийняття рішень для діагностування полягає в ідентифікації її параметрів і структури таким чином, щоб забезпечувалося прийнятне значення заданого критерію якості G . Таким чином, навчальні множини $S = \langle P, T \rangle$ містять офлайнві дані, отримані раніше шляхом спостережень за об'єктом діагностування та на основі яких синтезуються діагностичні моделі, які пізніше можуть використовуватися для діагностування в режимі онлайн.

Як цільовий критерій G при синтезі моделей діагностування можуть бути використані, наприклад:

– помилка розпізнавання (в задачах з дискретним виходом T) [1–7, 9–17], що обчислюється за формулою (1.4):

$$E = \frac{N_{er}}{Q}, \quad (1.4)$$

де N_{er} – кількість невірно розпізнаних спостережень вибірки S за синтезованою моделлю;

– середньоквадратична помилка (у випадках, коли вихідний параметр T може приймати дійсні значення з деякого діапазону $T \in [t_{\min}; t_{\max}]$) [1–7, 102–107], що визначається за формулою (1.5):

$$E = \frac{1}{Q} \sum_{q=1}^Q (t_q - t_{q\text{mod}})^2, \quad (1.5)$$

де $t_{q\text{mod}}$ – значення вихідного параметра q -го спостереження, розраховане за синтезованою моделлю.

1.3 Властивості та характеристики вибірок вхідних даних

Процес побудови діагностичних моделей суттєво залежить від властивостей і характеристик вихідних наборів даних $S = \langle P, T \rangle$. Наявність тих чи інших особливостей у вхідних вибірках даних (наявність пропущених значень, порушення частоти класів, великі обсяги даних і т.ін.) може впливати на ефективність застосування методів аналізу даних, знижувати достовірність отриманих результатів, накладати обмеження, а в деяких випадках і робити неможливим використання певних методів синтезу діагностичних моделей [1–7, 102–116].

Виділимо такі властивості та характеристики навчальних вибірок даних, які можуть впливати на ефективність застосування методів синтезу діагностичних моделей: обсяг вибірки, порушення частоти класів, наявність пропущених даних, типи атрибутів і вихідних параметрів.

Обсяг вибірки – кількість спостережень (об'єктів, прецедентів), поданих у вибірці даних. Це ключова властивість вибірок даних, яка впливає на можливість застосування різних методів їх обробки в процесі вирішення завдань діагностування. Недостатня кількість спостережень (вибірки малого обсягу), як правило, не дозволяє синтезувати діагностичні моделі, які характеризуються високими узагальнювальними та апроксимаційними здібностями. У той же час занадто великі обсяги даних ускладнюють процес їх обробки й аналізу [7, 14, 18, 27–30, 47, 67, 106–116].

В наш час у зв'язку зі збільшенням обчислювальних потужностей комп'ютерної техніки суттєво зростають обсяги наявної інформації. Так при вирішенні завдань технічного діагностування з'являються нові можливості вимірювання та збереження великої кількості параметрів діагностованих виробів (у т.ч. вимірювання параметрів в різні проміжки часу для різних виробів). Аналогічно в медичному діагностуванні зростають можливості

вимірювання величезної кількості характеристик (багато з яких вимірюються в часі) різних пацієнтів. Такі можливості призводять до накопичення великої кількості даних, доступних для аналізу з метою побудови діагностичних і розпізнавальних моделей.

Під великими даними (Big Data) розуміють набори структурованих і неструктурованих даних великих обсягів і, як правило, великого різноманіття (різних типів даних, з можливістю наявності пропущених, зашумлених або надлишкових даних) [117–122]. При цьому, як правило, не виділяють будь-яких конкретних числових характеристик, що дозволяють однозначно класифікувати набори даних як великі [117–122]. Це пов'язано з тим, що обчислювальні потужності комп'ютерної техніки постійно зростають, внаслідок чого практичний поріг оброблюваних даних також змінюється з часом. Крім того, постійно зростає і обсяг накопичуваних даних. Проблема визначення чисельного порога, що дозволяє віднести набори даних до великих, пов'язана також з неструктурованістю таких даних, що обумовлено наявністю різних типів даних в наявних наборах і можливістю пропусків та зашумленості даних.

Крім обсягу (volume) і різноманітності (variety), визначальними характеристиками великих даних [117–122] також є швидкість (velocity), достовірність (veracity) та цінність значення (value) [118, 120, 121]. При цьому під швидкістю розуміють швидкість накопичення нових даних, а в деяких випадках і швидкість їх обробки. Достовірність відноситься до правдивості даних і залежить від того, наскільки дані є репрезентативними, чи існують в даних невідповідності і т. ін. Під цінністю значення даних розуміють можливість генерування на їх основі нових знань і використання їх для досягнення будь-яких цілей при вирішенні практичних завдань.

Джерелами отримання великих даних можуть бути соціальні мережі, бізнес-системи (внутрішнє програмне забезпечення підприємств і організацій) і системи Інтернету речей [123–125]. В останніх двох випадках дані, як правило,

є досить структурованими і прийнятними для обробки при вирішенні завдань діагностування.

Проблеми обробки великих даних обумовлені такими їх особливостями:

– великі дані можуть бути розподілені фізично серед різних пристроїв зберігання даних (це обумовлено, в тому числі, і тим, що дані можуть генеруватися з різних джерел, наприклад, при зборі даних з різних пацієнтів при медичному діагностуванні або різних пристроїв / механізмів при технічному діагностуванні), а також поява нових даних з плином часу. Це призводить до необхідності перегляду (створення нових або модифікації існуючих) моделей діагностування або розпізнавання, створених раніше на основі наявної на поточний момент інформації;

– неструктурований характер даних, наявність даних різного типу, шумів, пропущених і суперечливих даних, що істотно ускладнює застосування відомих методів аналізу даних [57–63, 103–111, 126–132];

– наявність надлишкових даних. Як правило, у великих масивах інформації містяться надлишкові дані, наявність яких уповільнює процес обробки таких даних при синтезі діагностичних моделей, а також погіршує узагальнювальні й апроксимаційні властивості створених моделей. Це, в свою чергу, ускладнює застосування синтезованих моделей на практиці (такі моделі є не тільки складними, але і можуть не забезпечувати прийнятну точність діагностування).

Як правило, великі дані обробляють за допомогою існуючих методів інтелектуального аналізу даних (асоціативні правила, кластерний аналіз, регресійний аналіз та ін.) [57–63, 103–111, 133–141], машинного навчання із застосуванням нейромережевих технологій [31, 42, 77–80, 142–148], розпізнавання образів [45–50, 67, 77, 98, 130] і паралельних обчислень [149–163]. Однак наявність наведених вище особливостей великих даних і проблем їх обробки обумовлює потребу пошуку ефективних методів і засобів аналізу

при вирішенні конкретних прикладних задач, а також розробки нових і модифікації існуючих методів обробки діагностичних даних.

Важливою характеристикою навчальних вибірок даних $S = \langle P, T \rangle$, що впливає на можливість застосування різних методів синтезу діагностичних моделей, є порушення частоти класів. В процесі побудови моделей прийняття рішень для неруйнівного контролю якості, технічного та медичного діагностування, розпізнавання образів [1, 7–9, 17, 18] можуть виникати ситуації, коли більша частина інформації в навчальній вибірці даних відноситься до одного класу (наприклад, переважна більшість виробів відноситься до одного класу придатності, або більшість досліджуваних пацієнтів не є хворими на конкретне захворювання) [7–9, 23, 24, 35].

Нехай задано навчальну множину $S = \langle P, T \rangle$, в якій набір значень вихідного параметра подається у вигляді вектора $T = (t_q)_Q$, де $t_q \in T'$ – значення вихідного параметра q -го екземпляру; T' – множина можливих значень вихідного параметра (як правило, в задачах неруйнівного контролю якості та розпізнавання образів множина T' складається з двох елементів $T' = \{t'_0, t'_1\}$, що визначають клас придатності виробу, наприклад при $t_q = t'_0$ q -й виріб вважається придатним, при $t_q = t'_1$ – некондиційним). Тоді вважається, що у вибірці $S = \langle P, T \rangle$ порушено частоти класів, якщо кількість екземплярів вибірки одного класу (наприклад, екземплярів класу некондиційних $t_q = t'_1$) істотно відрізняється від кількості екземплярів іншого класу, що визначається нерівністю $0 \leq N_{t_q=t'_0} \ll N_{t_q=t'_1}$, де $N_{t_q=t'_0}$ и $N_{t_q=t'_1}$ – кількість екземплярів вибірки $S = \langle P, T \rangle$, значення вихідного параметра t_q яких дорівнює t'_0 та t'_1 , відповідно, $N_{t_q=t'_0} + N_{t_q=t'_1} = Q$.

У таких випадках для формалізації описів досліджуваних об'єктів або процесів доцільно синтезувати моделі на основі штучних імунних систем [164–173], що характеризуються можливостями навчання на основі екземплярів

тільки одного класу, а також високим рівнем адаптації. Для вирішення завдань, що характеризуються суттєвою відмінністю кількості екземплярів, що відносяться до різних класів, використовують штучні імунні системи, які працюють на основі принципів негативного відбору [174–187], який передбачає побудову набору детекторів (обчислювальних елементів), здатних до розпізнавання невідомих екземплярів [174–187]. Такий підхід дозволяє виявляти аномалії або випадкові зміни в діагностованих об'єктах, а також розпізнавати екземпляри чужих класів (класів об'єктів, екземпляри яких не представлені в навчальній вибірці) [174–187].

Однак відомі методи синтезу штучних імунних систем на основі негативного відбору [164–187] генерують надмірну кількість детекторів (можливих рішень задачі), висувають значні вимоги до обчислювальних ресурсів комп'ютеру, як правило, використовують інформацію тільки про один клас екземплярів («своїх», придатних і т.ін.), не враховуючи при цьому дані про екземпляри інших класів. Отже, актуальним є розробка методів синтезу штучних імунних систем на основі негативного відбору, вільних від зазначених недоліків. Крім того, діагностичні моделі на основі штучних імунних систем характеризуються низьким рівнем узагальнення. Не дивлячись на те, що детектори (правила) імунної системи окремо є легкими в сприйнятті та розумінні людиною, через низький рівень узагальнення, система детекторів має велику розмірність, і, отже, є складною для сприйняття і аналізу людиною, що в цілому призводить до зниження інтерпретовності діагностичної моделі на основі імунних систем [174–187].

Наявність пропущених даних в навчальній вибірці $S = \langle P, T \rangle$ також впливає на можливість застосування різних методів обробки діагностичних даних. Під пропущеними значеннями розуміють невідомі (незадані) значення p_{qm} ознак або вихідного параметра t_q , відсутність яких, як правило, викликана проблемами вимірювання таких параметрів (неможливість вимірювання деяких параметрів виробу в якомусь конкретному випадку, небажання пацієнта

проводити будь-які вимірювання в певний момент часу і т.ін.). Обробка даних, що містять пропущені значення, може здійснюватися одним з таких способів [188–194]:

– видалення екземплярів (Complete-case Analysis, або Listwise Deletion Method), що містять пропущені значення одного чи декількох атрибутів p_{qm} або вихідного параметра t_q . Такий підхід доцільно застосовувати при великих обсягах наявних даних $S = \langle P, T \rangle$, в яких пропущено досить мала кількість значень за умови, що при видаленні екземплярів з вихідної вибірки не порушується частота класів. Проте видалення екземплярів (ознак) призводить до втрати інформації, зниження репрезентативності вибірок $S = \langle P, T \rangle$ [188, 191, 192, 194] і, відповідно, до зниження точності діагностування за синтезованою моделлю;

– заповнення пропущених значень вручну. Такий підхід, аналогічно попередньому, призводить, як правило, до погіршення якості синтезованих діагностичних моделей. До цієї групи методів можна віднести індикаторний метод (Indicator Method), при якому пропускам в даних присвоюється деяке спеціальне значення (наприклад, missing, ? або будь-яке інше значення), яке служить ідентифікатором того, що дане значення є пропущеним. Перевагою індикаторного методу є можливість використання всієї наявної у вибірці $S = \langle P, T \rangle$ інформації. Однак застосування такого підходу вимагає розробки спеціальних алгоритмів обробки даних, що містять пропущені значення [188, 191, 192, 194]. Крім того, такий підхід може призвести до суттєвого спотворення результатів;

– використання статистично розрахованих значень (середнє арифметичне, мода, медіана) замість пропущених значень. Перевагою такого підходу є те, що він дозволяє використовувати всю доступну у вихідній вибірці $S = \langle P, T \rangle$ інформацію, не втрачаючи інформацію про екземпляри з пропущеними значеннями, і синтезувати моделі з більш високими показниками

точності класифікації або прогнозування. Однак при великих обсягах даних обчислення статистичних показників для заповнення всіх пропущених у вибірці $S = \langle P, T \rangle$ значень може вимагати суттєвих обчислювальних і часових витрат. Крім того, у випадку, якщо вихідна вибірка $S = \langle P, T \rangle$ містить дуже велику кількість пропущених значень, такий підхід також може виявитися малоефективним [188–194].

При заповненні пропущених значень важливо врахувати, що в деяких вибірках даних $S = \langle P, T \rangle$ (наприклад, у випадках, коли вибірка подана у вигляді набору транзакцій [133 – 140]) пропущених значень суттєво більше, ніж наявних. У таких випадках застосування описаних вище підходів є ускладненим, а іноді і неможливим.

При синтезі діагностичних моделей важливо розуміти, що набір даних $S = \langle P, T \rangle$, який описує особливості об'єктів генеральної сукупності, може характеризуватися атрибутами різних типів [7 – 9, 101, 103, 109, 115]. Тип атрибута визначається набором можливих значень, які може приймати атрибут, і суттєво впливає на можливість застосування тих чи інших методів обробки даних. Як правило, на практиці застосовуються такі типи атрибутів: номінальний, дискретний, числовий. Важливо відзначити, що реальні технічні та медичні об'єкти можуть характеризуватися різними типами як вхідних, так і вихідних змінних. Тому актуальною є розробка методів попередньої обробки даних і побудови діагностичних моделей, здатних працювати з вибірками даних, що містять інформацію про об'єкти, які характеризуються різними типами атрибутів.

Таким чином, в наш час наборам навчальних даних властиві наявність пропущених і суперечливих значень, різні типи вхідних атрибутів і вихідного параметру об'єктів вибірки, шумів, неструктурований характер даних, великі обсяги надлишкових даних та інші характеристики, які суттєво уповільнюють, ускладнюють, а в деяких випадках і роблять неможливим застосування існуючих методів обробки діагностичних даних. Наявність зазначених

недоліків обумовлює необхідність розробки нових методів і засобів обробки даних, здатних підвищити швидкість обробки інформації, а також поліпшити узагальнювальні та апроксимаційні властивості діагностичних моделей, синтезованих на основі наявних наборів даних.

1.4 Попередня обробка даних для синтезу діагностичних моделей

Як зазначено вище, навчальні набори даних $S = \langle P, T \rangle$ характеризуються набором властивостей і характеристик, які суттєво впливають на ефективність (а в деяких випадках і можливість застосування) методів аналізу даних і достовірність отриманих результатів (синтезованих діагностичних моделей). Тому до побудови діагностичних моделей з метою підвищення їх апроксимаційних і узагальнювальних здібностей, а також скорочення часу процесу синтезу моделей, виконують попередню підготовку вхідних даних [1, 4, 23, 37, 45, 47, 108–112, 188–194]. У процесі попередньої обробки вхідних даних $S = \langle P, T \rangle$ для їх подальшого використання з метою синтезу діагностичних моделей, як правило, вирішують такі завдання: інтеграція даних з різних джерел в одне узгоджене сховище; обробка пропущених даних; завдання редукції даних; завдання перетворення даних.

Завдання інтеграції даних з різних джерел (баз даних, кубів даних, файлів) в одне узгоджене сховище пов'язано з необхідністю об'єднання даних і усуненням неузгодженостей, дублікатів, конфліктів в даних. Дане завдання, як правило, вирішується в процесі розробки діагностичних програмних систем шляхом застосування методів теорії баз даних та інформаційних технологій, і не вимагає розробки нових і модифікації існуючих методів штучного інтелекту [7–9, 45, 47, 57–63, 97].

Завдання обробки пропущених даних, що відноситься до завдань очищення даних, потребує вирішення у випадках, коли у вихідній множині $S = \langle P, T \rangle$ деякі значення ознак p_{qm} або вихідного параметру t_q є не визначеними з тих чи інших причин. Як відзначено вище, для заповнення пропущених значень використовують різні підходи. Якщо кількість екземплярів з пропусками S_{missed} є відносно невеликою ($|S_{missed}| \ll |S|$), то ці екземпляри видаляються з вибірки і не беруть участі в подальшому при побудові діагностичної моделі. Аналогічно можна видалити всі значення певної ознаки p_m у випадку, якщо більшість її значень у екземплярів вибірки є пропущеними: $\frac{N(p_{qm} = missed)}{|S|} > \varepsilon_{missed}$, де $N(p_{qm} = missed)$ – кількість екземплярів, у яких значення p_{qm} ознаки p_m є не заданими, ε_{missed} – максимально допустима частка екземплярів з пропущеними значеннями конкретної ознаки. Проте видалення екземплярів або ознак з вибірки даних призводить, як правило, до втрати інформації, необхідної для побудови діагностичних моделей [188–194].

Тому для заповнення пропущених значень ознак, як правило, застосовують методи відновлення пропущених даних на основі наявної інформації $S = \langle P, T \rangle$ за допомогою статистичних підходів (наприклад, заповнення середніми, заповнення з упередженим підбором, підстановка з підбором всередині груп, підбір найближчого сусіда і т. ін.) [188–194] і методів, заснованих на моделюванні (метод відновлення по регресії, багатовимірні оцінка ланцюговими рівняннями і т. ін.) [188–194]. Такі методи є ефективними у випадках, коли наявних (непропущених) даних досить для відновлення пропущених значень.

Однак при вирішенні практичних завдань може виникнути потреба обробки даних, що містять велику кількість пропущених значень. У таких випадках відновлювати пропущені значення за допомогою описаних вище

методів не має сенсу. Доцільним є використання методів видобування асоціативних правил [133 – 141], оскільки вони дозволяють виявляти сховані залежності в даних, скорочувати розмірність даних, тим самим підвищуючи рівень узагальнення, а також знижуючи структурну і параметричну складність синтезованих на їх основі діагностичних моделей. У цьому випадку розглядається варіант вхідних даних, де деякі значення ознак або вихідного параметра можуть бути не визначені. У результаті застосування методів виявлення асоціативних правил створюється множина $A = \{A_1, A_2, \dots, A_{N_A}\}$ правил виду $A_r : P_r \rightarrow T_r$, де P_r – антецедент – ліва частина r -го правила A_r , що визначає набір умов виконання правила A_r ; T_r – консеквент – права частина r -го правила A_r , що визначає значення вихідного параметра при виконанні умов P_r правила A_r ; $N_A = |A|$ – кількість витягнутих правил [133 – 141].

Відомі методи видобування асоціативних правил SCF, SETM, Apriori, DHP, Eclat і інші [133 – 141] при формуванні наборів, що часто зустрічаються, у процесі синтезу правил використовують властивість антимонотонності підтримки (відповідно до якого підтримка набору елементів не перевищує значення підтримки кожної з його підмножин) або інші процедури [133 – 141], що обумовлює наступні недоліки цих методів:

- аналогічно до жадібної стратегії пошуку аналізуються всі можливі комбінації з високими значеннями підтримки, що при великій кількості ознак P у вихідній множині S вимагає перевірки великої кількості комбінацій ознак P_r , виконуючи істотну кількість проходів по базі S і витрачаючи на це великі ресурси пам'яті та часу роботи ЕОМ;

- такий підхід не дозволяє в процесі пошуку генерувати правила A_r з наборів ознак, що містять комбінації з низькими значеннями підтримки (комбінацій ознак, що зустрічаються рідко);

- при використанні такого підходу виявляються тільки правила, синтезовані на основі наборів, що часто зустрічаються, внаслідок чого не

випливають цікаві правила $A_r : P_r \rightarrow T_r$ з високим рівнем вірогідності $\text{conf}(A_r)$ при низькому рівні підтримки $\text{supp}(A_r)$. Це істотно знижує апроксимаційні й узагальнювальні здібності синтезованої на основі виділеного набору $A = \{A_1, A_2, \dots, A_{N_A}\}$ асоціативних правил моделі.

Крім того, більшість методів видобування асоціативних правил призначена для оброблення бінарних даних. У той же час більшість реальних задач розпізнавання образів, контролю якості, діагностування пов'язана з необхідністю оброблення чисельних даних, де більшість ознак приймають значення з деякого діапазону.

Потреба в усуненні зазначених недоліків обумовлює необхідність розробки нових методів обробки даних з пропущеними значеннями на основі видобування асоціативних правил.

Завдання редукції даних пов'язано з проріджуванням і стисненням вихідного набору даних $S = \langle P, T \rangle$ для зменшення розміру даних з мінімізацією втрат інформації. Як правило, зниження розмірності даних забезпечують шляхом відбору інформативних атрибутів, створення нових атрибутів або відбору екземплярів.

Нехай задана вибірка даних $S = \langle P, T \rangle$, що містить Q екземплярів, кожний з яких характеризується значеннями ознак $p_{q1}, p_{q2}, \dots, p_{qM}$ та вихідного параметра t_q . Тоді задача відбору інформативних ознак в ідеалізованій постановці [126–132, 195–203] може бути подана в такий спосіб: знайти комбінацію ознак P^* з вихідного набору даних $S = \langle P, T \rangle$, при якій досягається мінімум заданого критерію оцінювання якості набору ознак: $V(P^*) = \min_{Xe \in XS} V(Xe)$, де Xe – елемент множини XS ; $V(Xe)$ – критерій оцінювання значущості набору ознак Xe ; XS – множина всіх можливих комбінацій ознак, отриманих з вихідного набору ознак P . У даний час запропоновані різні критерії оцінювання індивідуальної і групової значущості $V(P)$ ознак.

Для оцінювання індивідуальної значущості широко використовується коефіцієнт парної кореляції [195], що застосовується у випадках, коли значення досліджуваної ознаки і вихідного параметра є безперервними. Однак такий критерій дозволяє оцінити наявність і ступінь тісноти лише лінійного зв'язку між двома параметрами. Інформаційний критерій [131, 195] і критерій, який передбачає обчислення ентропії ознаки, використовують інформаційний підхід для визначення індивідуальної значущості ознак. Такі критерії, на відміну від коефіцієнта парної кореляції, дозволяють оцінювати також і ступінь тісноти нелінійного зв'язку між ознаками [50, 195]. Однак в теорії інформації передбачається, що значення ймовірностей станів систем є, як правило, відомими. При вирішенні практичних завдань ці ймовірності визначаються на основі статистичних даних і являють собою випадкові величини. Тому тільки при нескінченно великому обсязі вихідних вибірок $S = \langle P, T \rangle$ їх значення можна вважати точними [45, 50, 62, 195]. Важливо відзначити, критерії засновані на інформаційному підході, припускають, що ознаки вибірки $S = \langle P, T \rangle$ є незалежними і таким чином, є важко застосовними при вирішенні реальних практичних завдань, в яких навчальні вибірки містять взаємозалежні ознаки [50, 62, 195]. У роботах [199, 200] запропоновано оцінювати значущість ознак на основі методу Relief, що дозволяє визначати інформативність взаємозалежних ознак на основі їх геометричного розташування в вибірці $S = \langle P, T \rangle$. Однак такі критерії дозволяли оцінювати лише індивідуальну значущість ознак і не могли використовуватися для оцінювання інформативності наборів ознак.

Для обчислення групової інформативності ознак можуть бути використані критерії, засновані на інформаційному підході (теоретико-інформаційний критерій, ентропія набору ознак і т.ін.) [131, 195]. Однак такі критерії мають ті ж недоліки, що аналогічні критерії, які використовуються для оцінювання індивідуальної інформативності. Крім того, можливість

використання таких критеріїв заснована на припущенні про нормальність розподілу образів, що становлять класи вибірки $S = \langle P, T \rangle$.

При вирішенні задачі відбору ознак для оцінювання групової інформативності часто використовують помилки моделей, синтезованих на основі оцінюваних наборів ознак $P^* \subseteq P$. Такий підхід пов'язаний зі значними обчислювальними і часовими витратами ресурсів при відборі ознак. Це обумовлено високою обчислювальною складністю процедури синтезу моделі для кожного з оцінюваних наборів ознак $P^* \subseteq P$, що ускладнює застосування на практиці відомих методів відбору ознак [45, 50, 62, 131, 195].

Таким чином, наявність недоліків існуючих критеріїв оцінювання індивідуальної і групової значущості обумовлює доцільність розробки системи критеріїв оцінювання інформативності ознак, вільної від виявлених недоліків.

В наш час для редукції даних шляхом відбору інформативних ознак використовується широкий спектр методів [126–132, 195–203].

Метод повного перебору передбачає оцінювання кожної з $2^M - 1$ можливих контрольних точок Xe простору пошуку XS [131, 132]. В силу повного перебору всіх можливих рішень $Xe \in XS$ такий метод дозволяє знайти рішення P^* , що характеризується оптимальним значенням цільової функції $V(P^*) = \min_{Xe \in XS} V(Xe)$. Оскільки обчислювальна складність такого методу $O(2^M)$ суттєво залежить від вихідної кількості ознак M навчальної вибірки $S = \langle P, T \rangle$, даний метод може використовуватися для відбору ознак з вибірок малого обсягу. Це суттєво ускладнює і робить неможливим застосування даного методу для обробки великих обсягів даних.

Евристичні методи (метод послідовного додавання ознак, метод послідовного видалення ознак) використовують жадібну стратегію пошуку, застосування якої передбачає почергове додавання (видалення) ознак до поточного набору ознак [131, 132, 195]. Такий підхід є більш простим у порівнянні з повним перебором і вимагає менше обчислювальних і часових

витрат. Проте комбінації ознак P^* , знайдені за допомогою таких методів, як правило, характеризуються неприйнятними значеннями критерію оптимальності $V(P^*)$, оскільки евристичні методи досліджують дуже обмежені області простору пошуку. В наслідок цього, комбінації ознак, що характеризуються оптимальним (або прийнятним) значенням цільового критерію $V(P^*)$ можуть бути не знайдені. Обчислювальна складність таких методів пропорційна квадрату кількості ознак M вихідної вибірки $S = \langle P, T \rangle$: $O(M^2)$. Тому застосування даного підходу при необхідності відбору ознак з великих вибірок даних також є проблемним.

Методи стохастичного пошуку засновані на застосуванні ймовірнісних процедур при обробці контрольних точок $Xe \in XS$, і, як правило, на кожній ітерації працюють з деякою множиною рішень $R(iter) = \{\chi_1, \chi_2, \dots, \chi_{N_\chi}\}$. Кожне k -е рішення $\chi_k \in R(iter)$ відповідає k -й досліджуваній на ітерації $iter$ контрольній точці Xe_k в просторі пошуку XS : $\chi_k \rightarrow Xe_k$. Такі методи як математичний базис можуть використовувати еволюційний, мультиагентний або інші підходи обчислювального інтелекту [57–63, 204–216]. Методи стохастичного пошуку за вказану кількість ітерацій $Iter$ обробляють $Iter \cdot N_\chi$ контрольних точок (де N_χ – кількість рішень, що обробляються на кожній ітерації стохастичного пошуку). Тому обчислювальна складність $O(Iter \cdot N_\chi)$ такого підходу не залежить безпосередньо від кількості ознак M у вихідній вибірці, що дозволяє його застосовувати для редукції великих обсягів даних. Однак такі методи схильні до зациклення в областях локальних оптимумів (в процесі пошуку спостерігається концентрування деякого набору пробних точок χ_k близько областей локальних екстремумів), що знижує ефективність їх застосування і збільшує час пошуку. Тому розширення досліджуваних областей простору пошуку XS забезпечується за рахунок використання великої кількості N_χ контрольних точок χ_k , досліджуваних на кожній ітерації. Такий підхід

також не є ефективним в силу низької різноманітності рішень у множині $R(iter)$. Крім того, використання великої кількості контрольних точок N_χ на кожній ітерації збільшує час пошуку.

Також для відбору ознак може використовуватися підхід, який передбачає ранжування ознак p_m за значеннями їх індивідуальної значущості $V(p_m)$ по відношенню до вихідного параметру T . Такий підхід є обчислювально простим (його обчислювальна складність $O(M)$), проте він не враховує взаємну залежність ознак. Тому на практиці в умовах взаємної залежності ознак такий підхід не дозволяє відібрати набори ознак, що характеризуються оптимальним або прийнятним значенням критерію оцінювання групової інформативності $V(P^*)$.

Таким чином, наявність недоліків існуючих методів відбору ознак обумовлює доцільність розробки нового методу, заснованого на стохастичному підході та високопродуктивних обчисленнях і вільного від виявлених недоліків.

Для синтезу діагностичних моделей, представлених у вигляді набору взаємопов'язаних обчислювальних елементів (наприклад, моделей на основі нейро-нечітких мереж [217–219]), доцільно заданий набір вихідних даних $S = \langle P, T \rangle$ перетворити в множину RB чітких продукційних правил виду $A_r : P_r \rightarrow T_r$. Потім в процесі структурного синтезу діагностичної моделі набір RB чітких продукційних правил відображаються в структуру нейронної мережі, яку далі в процесі параметричного синтезу можна донавчити за допомогою методів машинного навчання за наборами наявних експериментальних спостережень [220–222].

Таким чином, процес синтезу діагностичних моделей пов'язаний з необхідністю редукції даних шляхом видобування продукційних правил.

Нехай задана вибірка даних $S = \langle P, T \rangle$. Завдання видобування продукційних правил полягає в тому, щоб з вибірки $S = \langle P, T \rangle$ витягти набір правил $RB = \{rule_r\}$, що дозволяє з прийнятною точністю E апроксимувати

множину S , де $rule_r$ – r -те правило в наборі RB , що являє собою імплікації виду $P_r \rightarrow T_r$. Помилка розпізнавання за синтезованим набором правил $RB = \{rule_r\}$ може розраховуватися як відношення неправильно розпізнаних екземплярів N_{er} вибірки $S = \langle P, T \rangle$ до загальної кількості екземплярів Q : $E = N_{er} / Q$.

Існують різні методи видобування продукційних правил, зокрема: витяг правил з синтезованих нейромережових моделей [221, 222], на основі дерев розв'язків [220], гібридний підхід на основі видобування дерев розв'язків з синтезованих нейромоделей [221], витяг правил на основі мультиагентного підходу [223] і еволюційних методів [221].

Метод RX (Rule eXtracion [221, 222]) передбачає видобування правил з синтезованих нейромережових моделей. У базовому методі RX запропоновано синтезувати тришарову штучну нейронну мережу NN на основі вихідної вибірки даних $S = \langle P, T \rangle$ за допомогою відомих методів навчання [57–63, 77], наприклад шляхом зворотного поширення помилки. Потім синтезована нейронна мережа NN спрощується шляхом видалення зв'язків з малими значеннями вагових коефіцієнтів і повторно навчається. Процес спрощення відбувається ітеративно до тих пір, поки помилка класифікації за нейромережевою моделлю є прийнятною. Після цього з синтезованої нейромоделі NN виділяється набір продукційних правил $RB = RB(NN(S))$. При цьому безперервні ознаки дискретизуються шляхом розбиття діапазонів їх значень на деяку множину інтервалів. Відзначимо, що такий підхід вимагає побудови нейромережових моделей по всій вибірці даних $S = \langle P, T \rangle$. Вихідний параметр T_{NN} , розрахований за нейромоделлю NN , приймає різні значення з діапазону можливих значень функції активації вихідного нейрона. Це ускладнює процес дискретизації при генерації правил, а при обробці великих вибірок даних $S = \langle P, T \rangle$ робить даний процес дуже неефективним. Крім того, в результаті дискретизації значень ознак і вихідного параметра при видобуванні

правил суттєво знижується здатність витягнутих правил виконувати точні прогнози за новими спостереженнями. Метод RX відноситься до так званого декомпозиційного підходу (Decompositional approach) [220] до видобування правил на основі нейронних мереж. Методи видобування правил, засновані на використанні такого підходу зосереджені на отриманні правил на рівні окремих нейронів навченої нейронної мережі. Основною особливістю видобування правил за допомогою таких методів є те, що вихід кожного елемента (нейрона) повинен відображатися в двійковий результат, що відповідає певному правилу. Тому в якості функції активації нейроелементів, як правило, використовується порогова функція, а завдання видобування правил зводиться до пошуку набору таких входів, зважена сума яких перевищує значення зміщення нейрона. Коли така комбінація зв'язків знайдена, вона перетворюється на правило, в якому вихід цього нейрона є консеквентом (наслідком) входів. Потім правила $rule_r$, витягнуті на окремому нейроні, агрегуються для формування загального набору правил $RB = \{rule_r\}$.

Для видобування правил з наборів даних типу $S = \langle P, T \rangle$ також застосовують підхід на основі використання синтезованих дерев розв'язків [224, 225]. Для цього виконують побудову дерев розв'язків на основі відомих методів, зокрема ID3, CART, CHAID, QUEST, C4.5 [75, 76, 88, 89]. Далі на основі синтезованого дерева розв'язків здійснюють видобування набору правил $RB = \{rule_r\}$. Для цього обробляються усі можливі шляхи від кореня синтезованого дерева до його листів, у результаті чого будуються відповідні правила, що узагальнюють інформацію, подану в деякій множині екземплярів вихідної вибірки $S = \langle P, T \rangle$. Загальна кількість видобутих у таких спосіб правил дорівнює кількості листів (кінцевих вузлів, що містять значення вихідного параметра) синтезованого дерева розв'язків. Проте відомі методи ідентифікації дерев рішень мають певні недоліки, пов'язані з великою обчислювальною складністю, проблемами формування дерева рішень (ріст дерева, відсікання частини дерева) і т. ін. [75, 76, 88, 89]. Крім того, такі методи

використовують жадібну стратегію пошуку: якщо ознака була обрана один раз, і за нею виконано розбиття на підмножини, то метод не може повернутися назад і вибрати інший атрибут, який привів би до кращого розбиття, внаслідок чого часто синтезуються дерева розв'язків, що не забезпечують прийнятний рівень апроксимації [75, 76, 88, 89]. Таким чином, зазначений підхід є доволі ефективним, оскільки моделі на основі дерев розв'язків є досить інтерпретовними та легко можуть бути перетвореними на набір продукційних правил. Проте наявність зазначених недоліків методів синтезу дерев розв'язків обумовлює необхідність розробки нових методів видобування продукційних правил на основі дерев розв'язків, вільних від зазначених недоліків.

Іншим способом генерації продукційних правил є гібридний підхід на основі видобування дерев розв'язків з синтезованих нейромоделей [221]. Одним з методів, що відносяться до гібридного підходу, є метод TREPAN, в якому в якості базису використовується навчена за заданим набором даних $S = \langle P, T \rangle$ нейронна мережа NN . Після побудови нейронної мережі NN (для цього застосовуються відомі методи синтезу нейромоделей [57–63, 77]) виконується синтез дерева розв'язків DT . Кінцевим вузлам d_T (листям) синтезованого дерева DT в процесі побудови присвоюються значення прогнозованого класу $T = t_a$, в залежності від значень вузлів-перевірок d_{ab} , розташованих від кореня дерева до відповідного листа d_{dt} , і вихідних значень екземплярів множини $S = \langle P, T_{NN} \rangle$. При цьому вихідні значення екземплярів s_q для синтезу дерева DT розраховуються за вже синтезованою нейронною мережею NN (таким чином реальні виходи T екземплярів вибірки $S = \langle P, T \rangle$ при побудові дерева розв'язків DT не використовуються). Таким чином завдання методу TREPAN [226] зводиться до просіювання функції, представлені навченою нейромережевою моделлю NN , на дерево розв'язків DT . Після синтезу розв'язків DT , що відповідає нейромоделі NN , виконується витяг правил описаним вище способом. Метод TREPAN

відноситься до групи методів, які отримали назву педагогічного підходу (Pedagogical approach) до видобування правил. Такі методи розглядають навчену нейромережу як чорний ящик. При чому в якості базису можуть використовуватися не тільки нейронні мережі, а й інші моделі. Основна ідея в педагогічному підході полягає в тому, щоб розглядати витяг правил як задачу відображення вже синтезованої нейромоделі (або моделі іншого типу) в набір правил. В якості навчальної множини використовується набір прикладів $S = \langle P, T_{NN} \rangle$, де значення виходу t_{qNN} кожного екземпляра s_q обчислюється за моделлю NN як функція $t_{qNN} = t_{NN}(P_q)$ від значень його входів. Таким чином, основною відмінністю педагогічних методів від декомпозиційних (при декомпозиційному підході відбувається безпосереднє перетворення проміжної моделі $NN(S)$ в набір правил $RB = RB(NN(S))$) є те, що набір правил RB генерується на основі значень вхідних ознак P екземплярів навчальної множини S і відповідних їм виходів проміжної моделі $NN(S)$: $RB = RB(S, NN(S))$. Отже, згенеровані таким чином правила $RB = \{rule_r\}$ відображають отриману раніше функціональну залежність (подану у вигляді, наприклад, нейромережевої моделі $NN(S)$) на множину екземплярів навчальної вибірки S . Недоліком такого підходу є необхідність побудови додаткового апроксиматора, представленого у вигляді нейромережевої моделі, що вимагає значних витрат часу і обчислювальних ресурсів комп'ютеру. Крім того, побудова дерева на основі синтезованої нейромережі не гарантує його компактності та відсутність надлишкових гілок.

У методах видобування правил на основі мультиагентного підходу [223] для генерації бази правил $RB = \{rule_r\}$ використовуються структури даних, подані у вигляді інтелектуальних агентів $\chi = \{\chi_k\}, k = 1, 2, \dots, N_\chi$. Агенти являють собою структури даних (програмні сутності), які характеризуються деяким ступенем автономності та здатні до комунікації між собою, виконання певних дій в заданому просторі та взаємодії із зовнішнім середовищем [212–216].

Мультиагентна система являє собою набір автономних агентів, які взаємодіють один з одним в деякому середовищі для досягнення певних цілей. У роботах [223, 227] запропоновано мультиагентні методи, в результаті виконання яких агенти χ_k отримують правила з даних S , поданих у вигляді текстів (text mining), або від експертів (expert mining). Агенти взаємодіють з експертами, отримують відповіді на свої питання, з яких потім формують правила у вигляді множини структур типу «антецедент (питання) – консеквент (відповідь)». Інші агенти видобувають правила з текстів, попередньо класифікуючи їх на релевантні та нерелевантні по відношенню до деякої базової тематики. Далі в релевантних текстах виконується пошук і оцінювання шаблонів, що часто зустрічаються. Цей процес, як правило, складається з двох етапів: перетворення базового тексту у внутрішню форму або модель, обробка внутрішньої моделі шляхом видобування шаблонів або правил. Основним завданням в такому випадку є пошук і розпізнавання необхідного набору правил з текстових даних. Суттєвим недоліком цього підходу є те, що такі методи працюють лише з текстовими документами і експертами. Тому для вирішення завдань діагностування, де вхідна інформація подається, як правило, у вигляді чисельних наборів даних $S = \langle P, T \rangle$, доцільно розробити мультиагентні методи редукції чисельних наборів даних.

Для побудови бази правил також застосовують еволюційні методи [204–211, 221, 228]. У методі REGP (Rule Extraction with Genetic Programming [221, 228]) стратегія видобування продукційних правил заснована на генетичному програмуванні. При цьому набори правил RB_k представляються у вигляді структур даних χ_k , так званих хромосом, кожна з яких може відображати деяку модель (наприклад, дерево розв'язків, регресійне дерево, набір булевських правил і т. ін.). На кожному етапі еволюційного процесу над рішеннями χ_k виконуються еволюційні оператори відбору, схрещування і мутації [204–211]. Для оцінювання рішень χ_k використовується підхід, аналогічний гібридному

підходу з використанням нейромоделей. В якості цільової функції E_k , за допомогою якої оцінюється якість k -го рішення χ_k , використовується середньоквадратична помилка $E_k = \frac{1}{Q} \sum_{q=1}^Q (t_{qNN} - t_{qk})^2$, де t_{qk} – значення вихідного параметра q -го екземпляра s_q навчальної вибірки $S = \langle P, T \rangle$, розраховане за синтезованою моделлю RB_k (набором правил, що відповідає оцінюваному рішенню χ_k); t_{qNN} – значення вихідного параметра q -го екземпляру s_q навчальної вибірки $S = \langle P, T \rangle$, розраховане за вже побудованою нейромережевою моделлю NN . Отже, цільова функція E_k забезпечує пошук таких наборів правил RB_k , при яких досягається найбільша схожість з моделлю NN , синтезованою раніше по набору даних $S = \langle P, T \rangle$. Набори правил RB_k , згенеровані за допомогою такого підходу, узагальнюють заданий набір екземплярів $S = \langle P, T \rangle$ опосередковано через синтезовану раніше модель NN . Це в деяких випадках не дозволяє забезпечити прийнятний рівень апроксимації навчальної множини $S = \langle P, T \rangle$ синтезованим набором правил RB . Крім того, оскільки метод REGP вимагає до початку процесу генерації набору правил $RB = \{rule_r\}$ виконувати побудову проміжної нейромережевої моделі $NN(S)$, його використання на практиці пов'язано з додатковими витратами часу та обчислювальних ресурсів комп'ютера. Відомим недоліком мультиагентних і еволюційних методів [204–216] є суттєві витрати часу при виконанні обчислювальних процедур, що ускладнює їх застосування при вирішенні практичних завдань, особливо завдань обробки великих даних, і обумовлює необхідність модифікації існуючих і створення нових методів і засобів побудови наборів правил на основі еволюційних обчислень [221].

Таким чином, актуальним є завдання розробки нових методів видобування продукційних правил, вільних від виявлених вище недоліків, і які дозволяють ефективно обробляти різні вибірки даних.

У деяких випадках для підвищення ефективності процесу побудови діагностичних моделей доцільно виконати перетворення даних, представлених у вигляді навчальної вибірки $S = \langle P, T \rangle$. Під перетворенням даних $S = \langle P, T \rangle$ розуміють застосування деякої детермінованої функції $f(S)$ до кожного елементу множини S з метою подальшого використання методів аналізу даних для обробки вихідної вибірки S [57–63, 101–109]. До перетворення даних, як правило, відносять процедури [57–63, 101–109] нормалізації та перетворення одного типу даних в інший. Відомі методи перетворення даних є досить простими для реалізації, що обумовлює їх широке застосування на практиці при вирішенні завдань діагностування.

Таким чином, методи попередньої обробки даних використовуються до побудови діагностичних моделей для підвищення їх апроксимаційних і узагальнювальних здібностей, а також скорочення часу синтезу таких моделей. Існуючі методи підготовки даних, як правило, дозволяють ефективно вирішувати завдання інтеграції даних з різних джерел, обробки пропущених даних, редукції та перетворення даних. Однак при вирішенні практичних завдань діагностування може виникнути потреба обробки даних, що містять велику кількість пропущених значень, що ускладнює застосування відомих методів і обумовлює необхідність розробки нових методів обробки даних з пропущеними значеннями на основі видобування асоціативних правил.

Встановлено, що процес редукції даних при діагностуванні пов'язаний з необхідністю оцінювання інформативності ознак. Проте відомі критерії оцінювання індивідуальної та групової інформативності, як правило, ґрунтуються на припущенні про те, що ознаки вибірки $S = \langle P, T \rangle$ є незалежними величинами, інші критерії (коефіцієнт парної кореляції) дозволяють встановити ступінь тісноти зв'язку випадкових величин тільки лінійного виду, деякі критерії засновані на припущенні про нормальність розподілу випадкових величин, що суттєво ускладнює застосування таких критеріїв на практиці та викликає потребу розробки нових критеріїв

оцінювання індивідуальної та групової інформативності ознак. Обумовлено доцільність розробки нового методу відбору інформативних ознак, заснованого на стохастичною підході та високопродуктивних обчисленнях. Показано, що суттєві витрати часу при виконанні обчислювальних процедур в процесі редукції даних шляхом видобування продукційних правил ускладнюють застосування існуючих методів при вирішенні практичних завдань діагностування, що обумовлює необхідність модифікації існуючих і створення нових методів і засобів побудови наборів правил на основі еволюційних обчислень.

1.5 Побудова діагностичних моделей

Як відзначено вище, розробка програмних систем технічного та медичного діагностування пов'язана з необхідністю побудови математичних моделей за заданими набором спостережень $S = \langle P, T \rangle$.

Найбільш простим видом математичних моделей, які можуть застосовуватися для діагностування, є лінійні регресійні моделі [4, 8, 55, 105]. Такі моделі описують лінійні закономірності між вхідними змінними p_1, p_2, \dots, p_M та вихідним параметром t . У загальному випадку лінійні регресійні моделі представляються у вигляді $t = a_0 + a_1 p_1 + a_2 p_2 + \dots + a_M p_M$, де $a_0, a_1, a_2, \dots, a_M$ параметри моделі $t = t(p)$, що налаштовуються. Значення параметрів $a_0, a_1, a_2, \dots, a_M$ обчислюються за даними навчальної вибірки $S = \langle P, T \rangle$, використовуючи значення атрибутів p_{qm} і вихідного параметра t_q екземплярів вибірки. Для визначення значень параметрів $a_0, a_1, a_2, \dots, a_M$ (параметричного синтезу моделі) у випадку лінійної регресії, як правило, застосовують метод найменших квадратів [55, 103–107]. Перевага побудови

таких моделей для діагностування полягає в простоті обчислень значень параметрів моделі (при визначенні значень параметрів $a_0, a_1, a_2, \dots, a_M$ не використовуються складні високоітеративні обчислювальні процедури). Суттєвим недоліком лінійних моделей є те, що такі моделі дозволяють описувати лише лінійні закономірності між вхідними змінними та вихідним параметром.

Як діагностичні моделі можуть використовуватися нелінійні регресійні моделі, що дозволяють відображати нелінійні зв'язки певного виду. В якості базису для опису закономірності між атрибутами та вихідним параметром використовуються, наприклад, квадратична функція (регресійна модель $t = t(p)$ будується у вигляді $t = A_2 p^2 + A_1 p + A_0$, де A_2, A_1, A_0 – множина параметрів моделі, що налаштовуються та відображають ступінь вкладу квадратичних, лінійних і вільних членів в значення вихідного параметра), логарифмічна функція ($t = A_0 + A_1 \log p$), експоненціальна функція ($t = A_0 e^{A_1 p}$), ступенева функція ($t = A_0 p^{A_1}$) та інші функції [4, 8, 103–107]. Підбір параметрів A_0, A_1, A_2 , що налаштовуються, здійснюється аналогічно лінійній регресії за допомогою методу найменших квадратів [55, 103–107], що дозволяє побудувати регресійну модель так, щоб сума квадратів відхилень між реальним значенням вихідного параметру t_q екземплярів вибірки і значенням $t_{q \text{ mod}}$, розрахованим за

синтезованою моделлю, була мінімальною: $\sum_{q=1}^Q (t_q - t_{q \text{ mod}})^2 \rightarrow \min$. Суттєвим

недоліком використання регресійних моделей для діагностування є те, що такі моделі дозволяють описувати лише той тип залежності між випадковими величинами, який відповідає типу нелінійної зв'язку, що використовують як базис моделі (поліноміальний, логарифмічний, ступеневий і т. ін.). Це обумовлює необхідність залучення користувача в процес синтезу діагностичної моделі для завдання структури моделі (типу нелінійної функції, яку використовують як базис). Неправильний вибір типу моделі призведе до

побудови такої діагностичної моделі, яка буде характеризуватися низькими апроксимаційними та узагальнювальними здібностями, не забезпечуючи прийнятний рівень прогнозування або розпізнавання.

Іншим типом моделей, які можна використовувати для побудови систем діагностування, є класифікаційні моделі [4, 8, 53, 114], призначені для визначення класу (значення вихідного параметра T з заданої дискретної множини значень $T = \{t_1, t_2, \dots, t_{NT}\}$, де NT – кількість класів, різних значень вихідного параметра у вибірці $S = \langle P, T \rangle$) деякого екземпляра s_q за заданим набором значень атрибутів $p_{q1}, p_{q2}, \dots, p_{qm}$. Математично такі моделі можуть описуватися різними способами (наприклад, за допомогою геометричних координат центру деякої множини та її розмірів, дерева розв'язків, набору правил і т.ін.). Спосіб математичного опису залежить від методу, який використовується для побудови класифікаційної моделі [4, 8, 53, 114]. Одним з найбільш простих методів класифікації є метод еталонів (метод метричної класифікації) [4, 8, 53, 57–63, 114], що використовує гіпотезу про компактність розташування в просторі ознак схожих об'єктів (екземплярів навчальної вибірки $S = \langle P, T \rangle$, що відносяться до одного класу). При використанні такого методу визначаються еталони $Cl_1, Cl_2, \dots, Cl_{NT}$ екземпляри, координати яких розраховуються як середньоарифметичне значення координат екземплярів відповідного класу), кількість яких збігається з кількістю можливих значень NT , які може приймати вихідний параметр. Побудована таким чином класифікаційна модель являє собою множину координат центрів еталонів. Належність нового екземпляру до певного класу визначається виходячи з мінімуму відстані до відповідного еталону. При використанні методу k найближчих сусідів (knearest neighbors, kNN) [57–63] клас об'єкту визначається шляхом голосування відповідно до класів k його найближчих сусідів. Класифікаційною моделлю в такому випадку є вся вихідна вибірка даних $S = \langle P, T \rangle$, тому при великій кількості екземплярів у вибірці такий метод є

мало ефективним при використанні на практиці. Використовуються також інші методи класифікації [4, 8, 53, 57–63, 114] (метод потенційних функцій, метод парзенівського вікна, методи кластеризації та ін.), що дозволяють синтезувати класифікаційні моделі. Недоліком таких моделей є те, що вони призначені для роботи з навчальними наборами даних $S = \langle P, T \rangle$, де вихідний параметр T приймає значення з деякого дискретної, заздалегідь визначеної, множини $T = \{t_1, t_2, \dots, t_{NT}\}$. Якщо вихідний параметр T являє собою неперервну величину, яка може приймати будь-які значення з деякого інтервалу $T \in [t_{\min}; t_{\max}]$, то для можливості використання класифікаційних моделей необхідно попередньо дискретизувати значення вихідної змінної. При цьому деяка інформація буде втрачена. Якість же синтезованих за такими даними класифікаційними моделям може виявитися неприйнятною (забезпечується низька точність класифікації).

В якості діагностичних моделей можуть також використовуватися моделі у вигляді набору RB чітких продукційних правил $A_r : P_r \rightarrow T_r$. Консеквентом T_r (правою частиною) правила може виступати як дискретне значення (клас), так і деяка функція від вхідних змінних [220–228]. Ліва частина правила P_r (антецедент) описує набір умов (значень вхідних атрибутів), виконання яких призводить до консеквенту T_r . Перевагою таких моделей є їх висока інтерпретовність, оскільки навчальна вибірка $S = \langle P, T \rangle$ за допомогою набору правил RB виду $A_r : P_r \rightarrow T_r$ спрощується до доступного для розуміння виду причинно-наслідкових зв'язків між набором значень вхідних атрибутів p_1, p_2, \dots, p_M і вихідним параметром t . Недоліком таких моделей є те, що для апроксимації складних нелінійних залежностей з прийнятною точністю необхідно побудувати набір RB , що складається з дуже великої кількості правил $A_r : P_r \rightarrow T_r$, що ускладнює інтерпретацію синтезованої моделі. Крім того, як відзначено вище, методи видобування продукційних правил при розв'язанні завдань діагностування, пов'язаних з необхідністю обробки великих даних, вимагають суттєвих витрат часу й обчислювальних

ресурсів комп'ютерної системи, що ускладнює їх застосування на практиці [220–228].

Множину правил виду $A_r : P_r \rightarrow T_r$ можна подавати за допомогою моделей у вигляді дерев розв'язків $D = \{dt_q\}$, що представляють собою ієрархічні послідовні структури, де кожному об'єкту (екземпляру вибірки або продукційному правилу) відповідає єдиний вузол-рішення $dt_q = \langle dc_q, dl_q, dr_q \rangle$ [75, 76, 88, 89]. Вузол dt_q є структуру, в якій dc_q є функцією прийняття рішень на основі значень вхідних атрибутів (у випадку, якщо вузол є внутрішнім вузлом дерева D) або значення вихідної змінної (для зовнішніх вузлів, що називаються листями дерева розв'язків), dl_q та dr_q є посиланнями на лівого і правого нащадків q -го вузла, відповідно, та представляють собою структури, аналогічні dt_q [75, 76, 88, 89]. Обчислення значення вихідного параметра t_q для екземпляра s_q відбувається шляхом пересування по синтезованому дереву розв'язків $D = \{dt_q\}$ від кореневого вузла до зовнішнього в залежності від значень вхідних атрибутів. Суттєвою перевагою моделей на основі дерев розв'язків є простота інтерпретації навченої моделі, оскільки дерево розв'язків легко може бути перетворено в набір продукційних правил виду $A_r : P_r \rightarrow T_r$ [75, 76, 88, 89]. Моделі на основі дерев розв'язків в системах діагностування можуть використовуватися для вирішення завдань класифікації (вихідний параметр приймає значення з дискретної множини $T = \{t_1, t_2, \dots, t_{NT}\}$) і прогнозування (вихідний параметр приймає значення з неперервного інтервалу $T \in [t_{\min}; t_{\max}]$). Перевагами використання дерев розв'язків в якості діагностичних моделей є швидкий процес навчання моделі та висока інтерпретовність (побудовані дерева розв'язків є інтуїтивно зрозумілими ієрархічними моделями). В наш час запропоновано різні методи синтезу дерев розв'язків: ID3, CART (Classification and Regression Tree, метод побудови класифікаційних та регресійних дерев розв'язків), C4.5, NewId, ITrule, CHAID,

CN2 та ін. [75, 76, 88, 89]. Однак більшість з відомих методів синтезу використовують жадібний підхід [75, 76, 88, 89], при якому у випадку вибору атрибута для побудови деякого вузла, алгоритм не може повернутися назад і вибрати інший атрибут, який можливо забезпечив би краще розбиття у вузлі, і відповідно дозволив би побудувати більш ефективну модель. Деякі методи, наприклад метод ID3, не використовують процедуру відсікання дерева і не дозволяють обробляти числові атрибути або пропущені значення у вихідній вибірці $S = \langle P, T \rangle$. Іншим недоліком методів синтезу дерев розв'язків є схильність до перенавчання, що призводить в деяких випадках до побудови моделей з низькими узагальнювальними здібностями [75, 76, 88, 89].

У випадку, коли вхідні набори даних подані у вигляді транзакційних баз даних (списків деяких подій, що характеризуються певними атрибутами) або містять велику кількість пропущених значень доцільно будувати діагностичні моделі на основі наборів асоціативних правил $A = \{A_1, A_2, \dots, A_{N_A}\}$, $A_r : P_r \rightarrow T_r$ [133–141]. Як відзначено вище, такі моделі дозволяють встановлювати за заданими наборами спостережень закономірності між різними подіями. Такі моделі є дуже простою і зручною формою подання знань, тобто аналогічно описаним вище моделям характеризуються високою інтерпретовністю. Процес побудови моделей на основі асоціативних правил $A = \{A_1, A_2, \dots, A_{N_A}\}$, як правило, заснований на пошуку таких правил $A_r : P_r \rightarrow T_r$, підтримка і достовірність яких вище деяких наперед заданих порогових значень. При цьому важливо на початковому етапі правильно поставити пороги мінімальної підтримки та мінімальної достовірності, оскільки занадто великі значення порогу підтримки призводять до пошуку очевидних і добре відомих закономірностей. У той же час необґрунтовано малі значення підтримки призводять до знаходження занадто великої кількості N_A правил $A_r : P_r \rightarrow T_r$, більшість з яких можуть відображати лише один або декілька записів з вихідного набору даних, а побудовані таким чином моделі (набори

асоціативних правил $A = \{A_1, A_2, \dots, A_{N_A}\}$) будуть характеризуватися низькою здатністю до узагальнення даних і будуть громіздкими, що знизить їх інтерпретовність. Таким чином, необхідність залучення користувача в процес видобування асоціативних правил при визначенні порогів мінімальної підтримки та мінімальної достовірності ускладнює застосування на практиці відомих методів пошуку асоціативних правил [133–141]. Важливо відзначити, що побудова таких моделей в системах діагностування є доцільною лише у випадку великої кількості пропусків у навчальній вибірці $S = \langle P, T \rangle$ (кількість пропущених даних є схожою або суттєво перевищує кількість заданих значень атрибутів, що описують екземпляри вибірки) [133–141]. Крім того, як відзначено вище, відомі методи видобування асоціативних правил, можуть виявити нецікаві правила, включення яких в модель $A = \{A_1, A_2, \dots, A_{N_A}\}$ призводить до погіршення її апроксимаційних і узагальнювальних здібностей [133–141]. При обробці великих вибірок даних $S = \langle P, T \rangle$, кількість N_A виявлених правил може виявитися досить великою, що також погіршить рівні узагальнення і інтерпретовності синтезованої моделі $A = \{A_1, A_2, \dots, A_{N_A}\}$.

Для автоматизації розв'язання завдань технічного та медичного діагностування за допомогою експертних систем [1, 6, 18, 23, 37] в якості базису для побудови діагностичних моделей широко застосовуються моделі на основі нечіткої логіки [83–87]. Такі моделі дозволяють забезпечувати механізми для приблизних міркувань з використанням неточних рішень і неточно вимірених значень вхідних аргументів. Нечіткі моделі, як правило, подаються у вигляді нечітких баз правил – множини $FRB = \{FA_1, FA_2, \dots, FA_{N_R}\}$ нечітких правил $FA_r : FP_r \rightarrow FT_r$, які відображають зв'язки між вихідним параметром і набором вхідних аргументів, де N_R – кількість нечітких правил в базі FRB . Антецедент FP_r r -го нечіткого правила є набором значень лінгвістичних термів ft_{mr} , кожен з яких відповідає деякій змінній p_m :

$FP_r = \bigcap_{m=1}^M (ft_{mr})$. Консеквент FT_r нечіткого правила FP_r може бути представлений у вигляді нечіткого терма, чіткої константи (класу вихідної змінної) або чіткої функції f від вхідних атрибутів $f_r(p_m)$ [83–87]. Побудова правил FP_r пов'язана з необхідністю фазифікації вхідних змінних p_m (у випадку, коли атрибут приймає значення з деякого неперервного інтервалу $p_m \in [p_{m\min}; p_{m\max}]$, користувачеві необхідно розбити даний інтервал на деякі підмножини і визначити функції приналежності термів). Для врахування значущості кожного правила FA_r в базі FRB йому може ставитися у відповідність певний ваговий коефіцієнт w_r [83–87]. Для визначення значення вихідного параметра $t_{q\text{mod}}$ за синтезованою нечіткою моделлю FRB за заданим набором значень вхідних атрибутів екземпляра s_q спочатку виконується етап фазифікації, на якому визначаються ступені належності екземпляра кожного правила FA_r бази FRB , обчислюючи для цього значення функцій належності для кожного з термів вхідних змінних, які беруть участь у відповідному правилі. Потім виконується нечітке логічне виведення із застосуванням операцій усічення функцій належності та об'єднання (композиції) отриманих значень. У випадку, якщо консеквент FT_r правила FA_r в базі FRB задається у вигляді нечітких термів, то виконується нечітке логічне виведення Мамдані [84–87]. Нечітке логічне виведення Сугено (Такагі-Сугено) [84–87] виконується за нечіткою базою правил FRB , де вихід подається лінійною функцією f від вхідних атрибутів: $f_r(p_m) = a_{0r} + a_{1r}p_1 + a_{2r}p_2 + \dots + a_{Mr}p_M$, де $a_{0r}, a_{1r}, a_{2r}, \dots, a_{Mr}$ – коефіцієнти лінійної функції в r -му правилі FA_r . На останньому етапі виконується дефазифікація отриманих результатів (приведення нечіткого значення до чіткого) із застосуванням, наприклад, методу центру тяжіння [84–87]. Таким чином, нечіткі моделі дозволяють оперувати з результатами не дуже точних вимірювань атрибутів навчальної вибірки $S = \langle P, T \rangle$, замінюючи їх на нечіткі терми лінгвістичних змінних. Моделі на основі нечіткої логіки є досить

гнучкими, дозволяючи змінювати нечіткі правила та їх параметри, а також дозволяють об'єднати чисельну інформацію, що надходить з вимірювальних пристроїв, і експертну (лінгвістичну, якісну) інформацію від фахівців в прикладних областях [84–87, 229–235]. Проте відсутність чітких рекомендацій щодо створення нечітких систем і нечітких моделей обумовлює необхідність залучення користувача в процес моделювання для завдання важливих параметрів моделі (наприклад, функцій належності нечітких термів), що впливають в подальшому на її показники точності, а також здатність до узагальнення даних. Крім того, необхідність завдання для кожної вхідної і вихідної чітких змінних термів і функцій належності збільшує час створення нечітких моделей, а в деяких випадках (зокрема, при обробці вибірок $S = \langle P, T \rangle$ великого розміру) і зовсім не дозволяє будувати такі моделі із залученням користувача в процес визначення функцій належності [84–87, 229–235]. Етап фазифікації з використанням заданих користувачем функцій належності, що є необхідним в процесі нечіткого логічного виведення за чіткими вибірками даних $S = \langle P, T \rangle$, може призвести до втрати деякої інформації про фазифіковані змінні, що в свою чергу призводить до зниження апроксимаційних і узагальнювальних властивостей синтезованих нечітких моделей [84–87, 229–235].

Для побудови моделей в інтелектуальних системах діагностування також використовуються штучні нейронні мережі [77–81, 90–92, 142–148, 236]. Моделі на основі штучних нейронних мереж NN представляють собою множину обчислювальних елементів (штучних нейронів), пов'язаних між собою певним чином. Як правило, нейроелементи в таких моделях ієрархічно організуються у набори шарів, за якими вхідний сигнал (набір значень вхідних атрибутів об'єкту діагностування) поширюється від нейронів першого шару через нейрони прихованих шарів до вихідного шару [77–81, 236].

Нейромережева модель може бути описана набором даних, що відображають структуру моделі *struct* (множину обчислювальних елементів і

зв'язків між ними) та її параметри $param = param(struct)$ (множину вагових коефіцієнтів, що характеризують ступінь зв'язку між відповідними нейроелементами). Кожен нейрон (мінімальний структурний елемент моделі NN) реалізує певну обчислювальну функцію і може бути описаний набором даних $paramNr$, що містить інформацію про тип і параметри функції активації та дискримінантну (передаточну) функції нейрона, а також деякі інші параметри [77–81, 236]. Для обчислення значення вихідного параметру $t_{q\text{mod}}$ екземпляру s_q за багатошаровою нейромережевою моделлю NN з прямим розповсюдженням сигналу на її входи (входи нейронів першого шару моделі) надходить інформація про значення p_{qm} атрибутів p_1, p_2, \dots, p_M відповідного екземпляра s_q . Потім з урахуванням ваг кожного зв'язку між нейронами в моделі NN (параметрів моделі, які визначаються структурою $param = param(struct)$) обчислюються вихідні значення нейронів першого шару, які в якості вхідних значень надходять на нейрони прихованих шарів. Вихідні значення нейронів прихованих шарів надходять в якості вхідних аргументів на нейрони вихідного шару, що визначають значення виходу нейромоделі [77–81, 90–92, 142–148, 236].

Наявність і типи різних зв'язків (прямонаправлені, зворотні зв'язки, зв'язки між нейронами одного шару) визначають характер роботи нейромережевої моделі, її тип і можливість використання для вирішення конкретних прикладних завдань [77–81, 236]. Завдяки своїй структурі і можливості формування мережі з різної кількості та типів нейроелементів з різними зв'язками між ними, такі моделі дозволяють апроксимувати складні нелінійні залежності, є стійкими до шумів і адаптивними до змін у вхідних даних $S = \langle P, T \rangle$, і здатні до вирішення погано формалізованих завдань.

Завдання синтезу нейромережевої моделі NN за заданою множиною спостережень $S = \langle P, T \rangle$ полягає в ідентифікації її структури $struct$ (множини нейронів і зв'язків між ними) і параметрів $param = param(struct)$ (набору значень вагових коефіцієнтів) таким чином, щоб забезпечувалося прийнятне

значення заданого критерію якості G нейромоделі NN . В якості цільового критерію G при синтезі діагностичних моделей на основі нейронних мереж, як правило, використовують помилку розпізнавання або середньоквадратичну (середню абсолютну) помилку [77–81, 90–92, 142–148, 236].

Таким чином, для вирішення завдань діагностування, коли досліджувані об'єкти не є надто складними, і як правило, досить добре вивчені, ефективно можуть використовуватися регресійні та класифікаційні моделі, а також моделі на основі дерев розв'язків і нечіткої логіки. Однак, при вирішенні слабо формалізованих завдань, а також у випадках, коли аналізовані діагностичні об'єкти є досить складними та характеризуються великою кількістю описових атрибутів, неповнотою і суперечливістю вхідної інформації (навчальних вибірок даних), для опису і моделювання відповідних залежностей доцільно використовувати нейромереві моделі, що дозволяють виявляти та описувати складні залежності між вхідними та вихідною змінними з високою точністю, здатні до узагальнення даних і є стійкими до суперечливої інформації у вхідних даних.

Тому в якості базису для синтезу діагностичних моделей в цій роботі пропонується вибрати моделі на основі нейронних мереж, що характеризуються високими апроксимаційними та узагальнювальними здібностями. Крім того, такі моделі в силу їх природного паралелізму можуть бути легко реалізовані на паралельних обчислювальних системах, що дозволяє суттєво спростити процес (скоротити в рази час) діагностування на їх основі.

1.6 Діагностування на основі нейромеревих моделей

Як відзначено вище, для синтезу діагностичних моделей ефективно можуть використовуватися нейронні мережі, оскільки такі моделі дозволяють описувати залежності між вихідною та вхідними змінними з високою точністю,

володіючи високими апроксимаційними і узагальнювальними властивостями [77–81, 90–92, 142–148]. Проаналізуємо різні види нейромережових моделей, які можуть застосовуватися для синтезу діагностичних моделей.

Нейронні мережі прямого поширення (Feed forward neural networks) або багатошарові перцептрони (perceptrons) являють собою набір обчислювальних елементів (нейронів), які певним чином обробляють вхідні дані (обчислюють значення вихідного параметру по набору вхідних змінних) і передають результати таких обчислень на входи нейронів наступних шарів. Такі моделі можуть бути віднесені до керованих даними (data-driven), адаптивних технологій обчислювального інтелекту, здатних обробляти складні нелінійні залежності [77, 78, 80, 90, 142, 144]. Багатошарові перцептрони можуть ефективно використовуватися для вирішення завдань прогнозування, діагностування та розпізнавання. Однак при вирішенні завдань, що характеризуються великими обсягами навчальних вибірок $S = \langle P, T \rangle$, навчання (настройка параметрів моделі за допомогою традиційно використовуваних градієнтних методів [77, 78, 80, 90]) багатошарових перцептронів може вимагати суттєвих часових витрат, що в деяких випадках є неприйнятним. Крім того, такі моделі, як моделі типу чорного ящика, не дозволяють інтерпретувати отримані залежності між вхідними та вихідними змінними, що також ускладнює їх застосування на практиці.

Рекурентні нейронні мережі (Recurrent neural networks) – нейронні мережі з часовою затримкою, в яких присутні зворотні зв'язки між нейронами, що забезпечують здатність нейромережі запам'ятовувати деякі результати, отримані раніше. У таких мережах вхідні дані, отримані на попередніх ітераціях, є вхідними даними для поточних обчислень. Таким чином рекурентні нейронні мережі виконують одну і ту ж задачу для кожного елемента аналізованої послідовності, при цьому вихід такої нейромоделі залежить від попередніх обчислень [77, 78, 80, 90, 142, 144]. Навчання рекурентних нейронних мереж є обчислювально складним завданням, а також пов'язано з проблемою зникаючого градієнта (Gradient vanishing and exploding problems),

коли в процесі навчання вся накопичена раніше інформація раптово втрачається і перестає бути доступною для подальшого використання в мережі. Такі нейромоделі, як правило, не використовуються для діагностування за багатовимірними наборами вхідних даних $S = \langle P, T \rangle$, поданих у вигляді навчальних вибірок, однак ефективно можуть використовуватися для вирішення завдань обробки часових послідовностей, розпізнавання рукописного тексту і мови, автозаповнення даних, стиснення інформації та ін. [77, 78, 80, 90, 142, 144].

Мережі з довгою короткочасною пам'яттю (LSTM-мережі, Long short-term memory) – відносяться до рекурентних неймережевих моделей, в яких реалізовано механізми подолання проблеми зникаючого градієнта шляхом використання рекурентних вентилів (gates) забування [144, 237, 238]. Як правило, LSTM-модулі неймережевої моделі містять декілька вентилів (вхідний, вихідний і вентиль забування), які реалізуються у вигляді логістичної функції і застосовуються для контролю потоків даних в LSTM-модулях [144, 237]. При цьому вхідні вентилялі визначають ступінь входження інформації з попереднього шару мережі в пам'ять поточного LSTM-модуля, вихідні вентилялі – міру використання значення, що зберігається в пам'яті поточного блоку, при розрахунку вихідного значення LSTM-модуля, вентилялі «забування» – ступінь збереження значення в пам'яті блоку. Функції активації всередині рекурентних компонентів LSTM-модулів не використовуються, що дозволяє навчати такі мережі, зберігаючи при цьому пам'ять про попередні часові інтервали, і не допускати зникнення градієнта або штрафу в процесі навчання мережі. Аналогічно класичним рекурентним нейронним мережам такі моделі застосовуються для розпізнавання сигналів, мови, рукописного тексту та в інших завданнях, пов'язаних з необхідністю обробки рядів даних [144, 237].

Неймережеві моделі на основі керованого рекурентного блоку (Gated recurrent units, GRU) є спрощеною версією LSTM-моделей, в яких замість вхідного вентиля і вентиля забування використовується вдосконалений вентиль скидання (reset gate), що визначає ступінь використання інформації з

попереднього шару й інформації з пам'яті поточного блоку [144, 238]. Вихідний вентиль у таких моделях відсутній. Таким чином GRU-моделі, на відміну від LSTM-мереж, функціонують трохи швидше і мають менше параметрів (за рахунок відсутності вихідного вентиля). Такі нейромережеві моделі є досить ефективними при обробці мовних і музичних сигналів. Однак для вирішення завдань діагностування за наборами прецедентів застосування LSTM- та GRU-моделей є недоцільним [144, 238].

Двонаправлені рекурентні нейронні мережі (Bidirectional recurrent neural networks, bidirectional LSTM networks, bidirectional gated recurrent units) структурно схожі на відповідні односпрямовані рекурентні мережі. Основною відмінністю таких мереж від їх односпрямованих аналогів є те, що для навчання використовуються не тільки попередні елементи послідовності, а й наступні (передбачається, що значення виходу в конкретний момент часу залежить як від попередніх значень, так і від подальших значень сигналу). Це дозволяє більш ефективно прогнозувати та виділяти деякі особливості в послідовності, однак для цього потрібно більше часу і даних. Практичне застосування двонаправлених рекурентних нейронних мереж аналогічно їх односпрямованим аналогам [239].

Автокодувальники (Autoencoders) – нейронні мережі прямого поширення сигналу, мають рівну кількість нейронів на вхідному та вихідному шарах, що відповідає загальній кількості ознак (описових атрибутів) в розв'язуваній задачі. Такі мережі також симетричні відносно середнього (одного або двох) шару і мають кількість нейронів на прихованих шарах, як правило, меншу, ніж кількість нейронів на вхідному та вихідному шарах. Основне завдання таких мереж полягає в отриманні на виході мережі сигналу, що відповідає вхідному сигналу, забезпечуючи таким чином автоматичне кодування інформації. Автокодувальники застосовуються для зменшення зашумлення даних і зменшення розмірності багатовимірних даних для візуалізації. Також такі мережі можуть застосовуватися для навчання глибоких багат шарових мереж і попереднього навчання глибоких мереж без вчителя [144, 240].

Мащини Больцмана (Boltzmann machines) та обмежені машини Больцмана (Restricted Boltzmann machines) являють собою стохастичні рекурентні нейронні мережі, здатні навчатися з учителем і без учителя, і використовуються в якості блоків-компонент в архітектурі мереж глибокого навчання. Обмежені машини Больцмана можуть застосовуватися для вирішення комбінаторних завдань і завдань редукції даних, оскільки прихований шар такої моделі являє собою глибокі (приховані) ознаки в даних, які синтезуються в процесі навчання мережі [241].

Глибокі мережі переконань (Deep belief networks, DBN) є породжувальними моделями з декількома шарами прихованих змінних, в яких нейроелементи пов'язані з нейронами сусідніх шарів, проте не мають зв'язків між собою в межах одного шару [144, 241]. Як правило, глибокі мережі переконань (довіри) синтезуються як каскад (стек) автокодувальників або обмежених машин Больцмана, в яких прихований шар кожної підмережі є видимим для наступної підмережі. На етапі навчання кожна підмережа (обмежена машина Больцмана або автокодувальник) навчається кодуванню попередньої підмережі, забезпечуючи таким чином досить швидку реалізацію процесу навчання мережі без учителя. Таке «жадібне» пошарове навчання засноване на прийнятті локально оптимальних рішень з метою пошуку прийняттого, але можливо, не оптимального рішення [144, 241]. По закінченню такого навчання без учителя для можливості вирішення завдань класифікації можна здійснити точну настройку мережі шляхом її навчання з учителем за заданим набором даних [144, 241].

Згорткова нейронна мережа (Convolutional neural network, CNN; deep convolutional neural networks, DCNN) є односпрямованою багат шаровою нейронною мережею, в якій чергуються згорткові шари (convolution layers) і шари субдискретизації (pooling layers, subsampling layers, шари підвибірки) [241, 242]. При побудові згорткових мереж застосовується операція згортки, що передбачає поелементне множення кожного фрагменту досліджуваного зображення на деяку матрицю (ядро) з подальшим підсумовуванням результату

і відображенням його на відповідну позицію результуючого зображення. Такі мережі відносяться до технологій глибокого навчання. Навчання мереж, як правило, відбувається за допомогою методу зворотного поширення помилки [241, 242]. Згорткові мережі використовуються для вирішення задач обробки зображень (наприклад, розпізнавання об'єктів на зображеннях), проте також можуть застосовуватися для обробки звукових сигналів. Крім обмеженої області застосування таких мереж, їх недоліком також є занадто велика кількість параметрів, що настраюються, і, відповідно, суттєва залежність одержуваного результату від компетенції користувача такої моделі [241, 242]. Такі мережі можна комбінувати з іншими технологіями глибокого навчання, в результаті чого можна створювати інші типи мереж, аналогічні до згорткових. Наприклад, розгортальні нейронні мережі (Deconvolutional networks, DN) являють собою реверсивні згорткові мережі, які здатні за набором вхідних даних (слів і т.п.) видати відповідне зображення [241, 242].

Генеративна змагальна мережа (Generative adversarial networks, GAN) – метод машинного навчання, заснований на використанні двох конкуруючих між собою нейронних мереж: генеративної (Generator, G, поданої у вигляді розгортальної мережі) і дискримінаційної (Discriminator, D, поданої у вигляді згорткової мережі). Перша мережа (генератор) створює зразки, а друга, дискриміратор, співвідносить зразки, згенеровані першою мережею, на правильні та неправильні [243]. Потім результати роботи другої мережі подаються на вхід першої, яка намагається згенерувати нові зразки шляхом підбору латентних ознак таким чином, щоб друга мережа не змогла коректно розпізнати правильні та неправильні зразки. Таким чином мережі змагаються між собою. В результаті штучно створені зображення на виході першої мережі стають найбільш реалістичними, а друга мережа досягає певної точності розпізнавання. Такий підхід отримав поширення при вирішенні задач генерації фотореалістичних зображень, дизайну інтер'єру, відновлення тривимірних моделей сцени за набором фрагментів і т. ін. [243].

Машина екстремального навчання (Extreme learning machines) являють собою нейромережі прямого поширення з випадковими зв'язками. Такі

нейромоделі містять один шар прихованих нейронів, в якому вхідні ваги нейронів, що відображають значущість зв'язків між вхідними параметрами та нейроелементами єдиного прихованого шару, генеруються випадковим чином і не уточнюються в подальшому. В процесі параметричного синтезу машини екстремального навчання не використовують зворотне поширення помилки [244]. Налаштування параметрів (вагових коефіцієнтів) між нейронами прихованого і вихідного шарів здійснюється за один крок відповідно до методу найменших квадратів. В результаті синтезується нейромережева модель, яка не володіє високими апроксимаційними і узагальнювальними здібностями, однак процес синтезу такої мережі вимагає менших витрат у порівнянні з використанням градієнтних методів навчання [244].

Нейронні мережі Кохонена (Kohonen networks) – є нейромоделями, які містять шар лінійних формальних нейронів (шар Кохонена). У таких мережах на шарі Кохонена використовується правило «переможець отримує все», при якому одичне значення на виході отримує той нейрон, значення лінійної функції активації якого є найбільшим. Такі нейромоделі, як правило, навчаються без учителя та використовуються для вирішення завдань видобування наборів незалежних ознак, кластеризації, візуалізації багатовимірних даних [77, 78, 80, 90, 142, 144].

Відзначимо, що нейромережеві моделі у наш час розділяють на два класи: неглибокі (дрібні) нейронні мережі (Shallow Neural Network) та глибокі нейронні мережі (Deep Neural Network). Глибокі мережі складаються з декількох прихованих шарів, як правило, різних типів, на кожному з яких розташовано велику кількість нейронів. Такі мережі в якості вхідної інформації здатні приймати необроблені дані, зокрема зображення, тексти, звукові сигнали та ін. При синтезі таких мереж виникають проблеми вибору кількості прихованих шарів. Крім того, моделі на основі глибоких нейронних мереж, як правило, характеризуються низькими рівнями узагальнення даних та інтерпретовності, а також схильністю до перенавчання. Неглибокі нейронні мережі, як правило, мають один або два приховані шари. Вхідною інформацією

для таких мереж є вектори даних, що описують деякі об'єкти або процеси [217–219, 249–256]. Діагностичні моделі, побудовані на основі неглибоких мереж, містять меншу кількість нейроелементів та зв'язків між ними, а отже є більш інтерпретованими. Таким чином, враховуючи характер оброблюваних даних, а також більш високі рівні інтерпретовності та узагальнення даних, для синтезу діагностичних моделей доцільно обрати неглибокі нейронні мережі, зокрема нейро-нечіткі мережі [245–262].

В якості діагностичних моделей на основі нейронних мереж ефективно можуть застосовуватися нейро-нечіткі мережі (ННМ). ННМ являє собою систему нечіткого виводу у вигляді нейронної мережі, зручної для навчання, поповнення знань, аналізу та використання [217–219, 245–262]. Моделі на основі нейро-нечітких мереж здійснюють виведення (обчислюють значення вихідного параметру) на основі методів нечіткої логіки, а параметри моделі (параметри функцій належності) налаштовуються за допомогою методів навчання нейромереж [77–81, 90–92, 142–148, 217–219]. В даний час запропоновано різні види нейро-нечітких мереж (кооперативні нейро-нечіткі системи, конкурентні нейро-нечіткі системи, гібридні моделі [217–219, 245–262]). До моделей на основі нейро-нечітких мереж відносять [249–256]: ANFIS, Мамдані, FALCON, NEFCON, FUN, GARIC, SONFIN, FINEST, EFuNN, dmEFuNN та інші.

Для розв'язання завдань діагностування широко використовують нейро-нечіткі моделі типу ANFIS (Adaptive-Network-based Fuzzy Inference System, адаптивна мережева система нечіткого виведення) [217, 249–256]. Нейро-нечітка мережа ANFIS є нейронною мережею прямого поширення, яка заснована на системі нечіткого логічного виведення Такагі-Сугено [249–256], де антецеденти правил задаються нечіткими термами за допомогою відповідних функцій належності, а консеквентами є поліноміальні лінійні функції першого порядку. Нейро-нечітка модель NFN типу ANFIS (рис. 1.1) забезпечує ізоморфність нечіткій базі знань $FRB = \{FA_1, FA_2, \dots, FA_{N_R}\}$ [249–256] і

складається з нейроелементів, що реалізують правила $FA_r : FP_r \rightarrow FT_r$ нечіткої бази FRB з використанням функцій належності чітких значень атрибутів p_1, p_2, \dots, p_M їх нечітким термам ft_{mr} , і механізм нечіткого логічного виведення, що дозволяє за наявним набором правил $FRB = \{FA_1, FA_2, \dots, FA_{N_R}\}$ для екземпляра $s_q = \{p_{q1}, p_{q2}, \dots, p_{qM}\}$ визначити значення вихідного параметра $t_q = t(NFN, s_q)$. Параметри нейро-нечіткої моделі NFN (параметри функцій належності та параметри функцій-консеквентів), як правило, налаштовуються за допомогою відомих методів навчання нейромоделей [77–81, 249–256].




Рисунок 1.1 – Нейро-нечітка мережа ANFIS [249–256]

На рисунку зображено нейро-нечітку мережа ANFIS для випадку двох вхідних змінних p_1 та p_2 , перша з яких розбивається на три нечіткі терми (ft_{11} , ft_{12} , ft_{13}), а друга – на два терми (ft_{21} , ft_{22}). На першому шарі такої мережі відбувається перетворення чітких значень вхідних атрибутів p_1, p_2, \dots, p_M екземпляру $s_q = \{p_{q1}, p_{q2}, \dots, p_{qM}\}$ в нечіткі множини шляхом застосування функцій належності (процес фазифікації). На виходах нейронів $\mu_{mr}^{(1)}$ першого шару обчислюються ступені належності значень вхідних атрибутів p_{qm} відповідним нечітким термам ft_{mr} ($m = 1, 2, \dots, M$, $r = 1, 2, \dots, N_{\text{int } m}$): $\mu_{mr}^{(1)} = \mu_{mr}^{(1)}(p_{qm})$, де $\mu_{mr}^{(1)}$ – функція, яка визначає належність значення m -го атрибуту p_{qm} r -му правилу (функція, яка визначає значення виходу mr -го нейрону першого шару мережі) нечіткої бази правил $FRB = \{FA_1, FA_2, \dots, FA_{N_R}\}$, що відповідає нейро-нечіткій моделі NFN ; $N_{\text{int } m}$ – потужність терм-множини (кількість інтервалів розбиття діапазону значень) m -го атрибуту [249–256]. Кількість нейроелементів першого шару N_1 мережі NFN визначається як сума потужностей терм-множин атрибутів p_1, p_2, \dots, p_M вибірки $S = \langle P, T \rangle$, за якою синтезується модель:

$N_1 = \sum_{m=1}^M N_{\text{int } m}$. Як функції належності $\mu_{mr}^{(1)}$ можуть використовуватися [249–256]:

– гауссова $\mu_{mr}^{(1)}(s_q) = e^{-\frac{(p_{qm} - w_{0mr})^2}{2w_{1mr}^2}}$;

– колоколоподібна $\mu_{mr}^{(1)}(s_q) = \frac{1}{\left(1 + \left|\frac{p_{qm} - w_{0mr}}{w_{1mr}}\right|\right)^{2w_{2mr}}}$;

– трапецієподібна $\mu_{mr}^{(1)}(s_q) = \begin{cases} 0, & p_{qm} < w_{0mr}; \\ \frac{p_{qm} - w_{0mr}}{w_{1mr} - w_{0mr}}, & w_{0mr} \leq p_{qm} < w_{1mr}; \\ 1, & w_{1mr} \leq p_{qm} \leq w_{2mr}; \\ \frac{w_{3mr} - p_{qm}}{w_{3mr} - w_{2mr}}, & w_{2mr} < p_{qm} \leq w_{3mr}; \\ 0, & p_{qm} > w_{3mr}; \end{cases}$

$$- \text{П-подібна } \mu_{mr}^{(1)}(s_q) = \mu S_{mr}^{(1)}(s_q) \mu Z_{mr}^{(1)}(s_q),$$

$$\mu S_{mr}^{(1)}(s_q) = \begin{cases} 0, & p_{qm} < w_{0mr}; \\ \frac{p_{qm} - w_{0mr}}{w_{1mr} - w_{0mr}}, & w_{0mr} \leq p_{qm} < w_{1mr}; \\ 1, & p_{qm} > w_{1mr}; \end{cases} \quad \mu Z_{mr}^{(1)}(s_q) = \begin{cases} 1, & p_{qm} < w_{0mr}; \\ \frac{w_{1mr} - p_{qm}}{w_{1mr} - w_{0mr}}, & w_{0mr} \leq p_{qm} < w_{1mr}; \\ 0, & p_{qm} > w_{1mr}; \end{cases}$$

де w_{0mr} , w_{1mr} , w_{2mr} , w_{3mr} – настроювані параметри функції належності m -го атрибута r -му правилу нечіткої бази правил FRB . Крім наведених вище, можуть використовуватися й інші функції належності [217–219, 249–256].

На другому шарі нейро-нечіткої моделі NFN з термів (нейронів першого шару) формуються рядки-кон'юнкції антецедентів нечітких правил

$$FP_r = \bigcap_{m=1}^M (ft_{mr}).$$

Виходом нейронів другого шару є ступінь виконання r -х правил

бази FRB , що обчислюється як добуток значень виходів нейронів першого шару $\mu_{mr}^{(1)}$, які відповідають лінгвістичним термам r -го правила:

$$\mu_r^{(2)}(s_q) = \bigcap_{m=1}^M \mu_{mr}^{(1)}(p_{qm}) \quad [249–256] \quad (\text{можливий варіант використання функції}$$

мінімуму належностей $\mu_r^{(2)}(s_q) = \min_{m=1,2,\dots,M} (\mu_{mr}^{(1)}(p_{qm}))$). Кількість нейроелементів

другого шару N_2 мережі NFN визначається як добуток потужностей терм-множин атрибутів p_1, p_2, \dots, p_M і відповідає кількості нечітких правил N_R

моделі NFN : $N_2 = \prod_{m=1}^M N_{\text{int } m} = N_R$. У випадку, якщо деякі з термів ft_{mr} не задіяні

при формуванні антецедентів FP_r правил, кількість нейронів N_2 на другому шарі буде меншою за добуток потужностей терм-множин

атрибутів: $N_2 < \prod_{m=1}^M N_{\text{int } m} = N_R$.

Третій шар нейромоделі ANFIS є шаром нормалізації. На третьому шарі обчислюються відносні ступені виконання r -х правил бази FRB [249–256]:

$$\mu_r^{(3)}(s_q) = \overline{\mu_r^{(2)}}(s_q) = \frac{\mu_r^{(2)}(s_q)}{\sum_{r=1}^{N_R} \mu_r^{(2)}(s_q)}.$$

Процес дефазифікації, що полягає в перетворенні нечітких значень в чіткі, виконується на четвертому шарі мережі ANFIS. Нейрони четвертого шару $\mu_r^{(4)}$ відповідають функціям $f_r^{(4)}(p_1, p_2, \dots, p_M)$ консеквентів правил $FA_r : FP_r \rightarrow FT_r$, сукупність яких визначає значення виходу моделі NFN . Як правило, функції $f_r^{(4)}(p_1, p_2, \dots, p_M)$ подаються у вигляді лінійних регресій $f_r^{(4)}(p_1, p_2, \dots, p_M) = \mu_r^{(3)}(s_q)(a_{0r} + a_{1r}p_1 + a_{2r}p_2 + \dots + a_{Mr}p_M)$, де $a_{0r}, a_{1r}, a_{2r}, \dots, a_{Mr}$ – параметри, що настроюються, моделі $f_r^{(4)}$. Таким чином кожен r -й нейроелемент четвертого шару моделі NFN визначає внесок нечіткого правила $FA_r : FP_r \rightarrow FT_r$ в загальний вихід мережі $t_{NFN}(p_1, p_2, \dots, p_M)$ [249–256]. Кількість нейроелементів третього і четвертого шарів дорівнює кількості нечітких правил N_R моделі NFN .

На п'ятому шарі визначається значення виходу t_{NFN} нейро-нечіткої моделі NFN як сума виходів нейроелементів попереднього шару:

$$t_{NFN}(s_q) = \mu^{(5)}(s_q) = \sum_{r=1}^{N_R} f_r^{(4)}(s_q) [249–256].$$

Для налаштування параметрів функцій належності і функцій, реалізованих у консеквентах правил, модель ANFIS використовує гібридне правило навчання [249–256], що поєднує алгоритм зворотного поширення помилки і метод найменших квадратів для ідентифікації та оптимізації параметрів своєї системи нечіткого виведення. Тому для можливості навчання таких нейро-нечітких моделей використовуються диференційовані функції належності.

На кожній ітерації навчання такої моделі значення виходів нейроелементів обчислюються від першого до третього шару нейромоделі NFN . На четвертому шарі обчислюються параметри $a_{0r}, a_{1r}, a_{2r}, \dots, a_{Mr}$ функцій $f_r^{(4)}$, що реалізують консеквенти правил, застосовуючи для цього метод найменших квадратів (при цьому в процесі настройки значень коефіцієнтів $a_{0r}, a_{1r}, a_{2r}, \dots, a_{Mr}$ параметри w_{mr} функцій належності $\mu_{mr}^{(1)}$ є фіксованими). Потім обчислюється значення виходу мережі t_{NFN} за даними навчальної вибірки $S = \langle P, T \rangle$, після чого помилки поширюються назад від останнього шару до першого для налаштування параметрів w_{mr} функцій належності $\mu_{mr}^{(1)}$ антецедентів правил за допомогою градієнтної оптимізації (при цьому параметри $a_{0r}, a_{1r}, a_{2r}, \dots, a_{Mr}$ функцій $f_r^{(4)}$ є фіксованими) [249–256]. Однак такий процес налаштування параметрів нейромоделі ANFIS є досить повільним і має схильність до зациклення в областях локальних мінімумів.

Для розв'язання завдань діагностування також ефективно використовуються нейро-нечіткі моделі Мамдані, які представляють собою нейронну мережу прямого поширення, засновану на системі нечіткого логічного виведення Мамдані [251–256]. У таких мережах, аналогічно моделям типу ANFIS, антецеденти правил задаються нечіткими термами за допомогою відповідних функцій належності. Однак консеквентами FT_r правил FA_r в нейро-нечітких мережах Мамдані є нечіткі терми вихідної змінної t . Нейро-нечітка модель типу Мамдані (рис. 1.2) аналогічна ANFIS-моделям, складається з нейроелементів, які реалізують правила $FA_r : FP_r \rightarrow FT_r$ нечіткої бази $FRB = \{FA_1, FA_2, \dots, FA_{N_R}\}$ і механізм нечіткого логічного виведення, що дозволяє за наявним набором правил FRB для екземпляра $s_q = \{p_{q1}, p_{q2}, \dots, p_{qM}\}$ визначити значення вихідного параметра $t_q = t(NFN, s_q)$. Параметри нейро-нечіткої моделі Мамдані (параметри функцій належності), як правило, налаштовуються за допомогою відомих методів навчання нейромоделей.

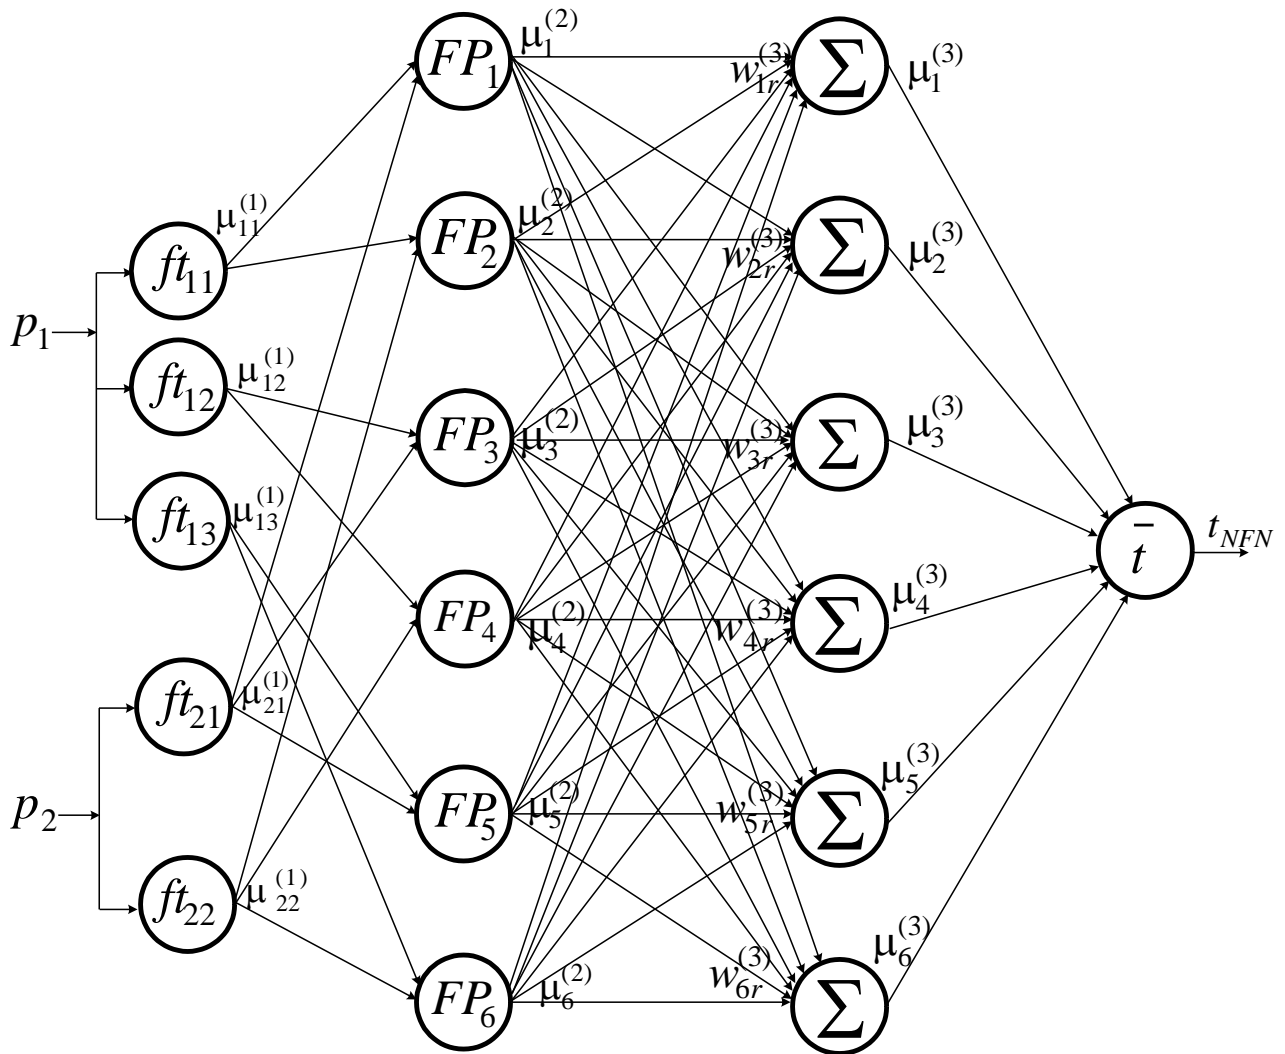


Рисунок 1.2 – Нейро-нечітка мережа Мамдані для двох вхідних змінних

Як видно з рисунку 1.2, перший і другий шари нейронів мереж Мамдані аналогічні відповідним шарам в нейро-нечітких моделях ANFIS [249–256].

Нейрони третього шару в моделі Мамдані дозволяють визначати ступінь належності вхідного екземпляра $s_q = \{p_{q1}, p_{q2}, \dots, p_{qm}\}$ відповідним термам $t_1, t_2, \dots, t_{N_{int}}$ вихідної змінної t з урахуванням ступенів виконання $\mu_r^{(2)}(s_q) = \min_{m=1,2,\dots,M} (\mu_{mr}^{(1)}(p_{qm}))$ r -х правил бази FRB , обчислених на попередньому шарі [251–256]. Кількість нейронів на третьому шарі відповідає кількості правил N_R бази FRB , яка, як правило, відповідає потужності терм-множини

(кількості інтервалів розбиття діапазону значень) вихідної змінної t : $N_3 = N_R = N_{\text{int } t}$ [251–256]. Вихідні значення $\mu_r^{(3)}(s_q)$ нейронів третього шару можуть бути обчислені в такий спосіб: $\mu_r^{(3)}(s_q) = \max_{a=1,2,\dots,N_{\text{int } t}} \{w_{ar}^{(3)} \mu_r^{(2)}(s_q)\}$ або $\mu_r^{(3)}(s_q) = \sum_{a=1}^{N_{\text{int } t}} w_{ar}^{(3)} \mu_r^{(2)}(s_q)$, $r = 1, 2, \dots, N_R$. Параметри $w_{ar}^{(3)}$ є налаштовуваними та відображають ваги нейронів третього шару, які визначають значущість зв'язку від нейронів другого шару до третього [251–256]. Ваги $w_{ar}^{(3)}$ відображають відповідність a -го терму вихідного параметру r -му правилу нечіткої бази знань. Параметри $w_{ar}^{(3)}$ визначаються, як правило, за допомогою градієнтного методу зворотного поширення помилки [77–81, 90–92, 142–148, 251–256].

Нейрон четвертого шару призначений для забезпечення дефазифікації (приведення від нечіткого до чіткого виду) отриманих раніше даних. Вихід нейрону четвертого шару обчислюється як зважена сума чітких значень термів вихідної змінної t урахуванням ступенів їх належності $\mu_r^{(3)}(s_q)$,

$$\text{використовуючи формулу: } t_{NFN}(s_q) = \mu^{(4)}(s_q) = \frac{\sum_{r=1}^{N_R} t_r \mu_r^{(3)}(s_q)}{\sum_{r=1}^{N_R} \mu_r^{(3)}(s_q)}.$$

Таким чином, нейро-нечіткі мережі NFN являють собою нелінійні моделі, які є легкими у використанні та розумінні, а також, на відміну від статистичних та регресійних моделей [217–219, 249–256] є універсальними апроксиматорами, що дозволяє їх використовувати для відновлення складних нелінійних залежностей різних вибірок даних $S = \langle P, T \rangle$. Оскільки ННМ відносяться до непараметричних моделей, вони не висувають жодних вимог до параметрів оцінюваних величин (не потрібні будь-які припущення про співвідношення параметрів розподілу досліджуваних величин). На відміну від багатозарових персептронів, які являють собою, по суті, моделі чорного ящика (за якими користувач не може пояснити, яким чином обчислюється значення

вихідного параметра за заданим набором вхідних ознак), ННМ є більш доступними до розуміння експертами в прикладних областях, дозволяють генерувати набори легко доступних та інтерпретованих продукційних правил. Крім того, такі моделі дозволяють більш ефективно обробляти набори, що характеризуються невизначеністю та суперечливістю даних [217–219, 249–256].

Тому в якості базису для побудови моделей прийняття рішень для діагностування та неруйнівного контролю якості доцільно використовувати нейро-нечіткі мережі [217–219, 249–256], які є гібридною моделлю обчислювального інтелекту, характеризуються високою інтерпретованістю (здатністю пояснення способу прийняття рішення) і поєднують у собі властивості систем, заснованих на знаннях, і однорідних обчислювальних структур (нейронних мереж): можливі наявні експертні знання у вигляді чітких продукційних правил відображаються у структуру нейронної мережі, яку потім можна донавчити за допомогою методів машинного навчання за набором наявних експериментальних спостережень.

1.7 Методи синтезу діагностичних моделей на основі нейро-нечітких мереж

Нехай задано множину спостережень (об'єктів, процесів діагностування) $S = \langle P, T \rangle$. Тоді задача синтезу моделі NFN на основі нейро-нечітких мереж полягає в ідентифікації її структури (кількість нейроелементів, зв'язки між ними) та параметрів (множина параметрів функцій належності, набір значень вагових коефіцієнтів моделі) таким чином, щоб забезпечувалося прийнятне значення заданого критерію якості G нейромоделі NFN . Як цільовий критерій G при навчанні нейро-нечітких моделей можуть бути використані, наприклад, помилка розпізнавання (в задачах з дискретним виходом T) або

середньоквадратична помилка (у випадку, коли вихідний параметр T може приймати дійсні значення з деякого діапазону $T \in [t_{\min}; t_{\max}]$).

Таким чином, процес побудови діагностичних моделей на основі нейро-нечітких мереж може бути поданий двома етапами. На першому етапі виділяються нечіткі терми ft_{mr} ($m = 1, 2, \dots, M$, $r = 1, 2, \dots, N_{\text{int } m}$) вхідних ознак (етап пов'язаний з необхідністю видобування правил на основі заданих вибірок даних $S = \langle P, T \rangle$), що визначає структуру синтезованої нейро-нечіткої моделі (структурний синтез). На другому етапі виконується обчислення параметрів нейромоделі, що настроюються на основі оптимізаційного підходу (параметричний синтез).

Для виділення термів ft_{mr} ознак [263] у процесі структурного синтезу нейро-нечітких моделей необхідно задати нечітке розбиття вхідного набору ознак p_1, p_2, \dots, p_M на деякі підмножини. Для цього використовуються різні методи, як правило, пов'язані з розбиттям діапазону значень вхідних ознак $[p_{m \min}; p_{m \max}]$ на інтервали або з кластеризацією даних (наприклад, за допомогою методу нечітких с-середніх [45, 47, 59]). В залежності від способу виділення нечітких термів ft_{mr} ознак p_m для одного і того ж набору вхідних даних $S = \langle P, T \rangle$ можуть бути побудовані різні нейро-нечіткі моделі NFN . Тому важливим є етап виділення нечітких термів ft_{mr} для побудови бази нечітких правил $FRB = \{FA_1, FA_2, \dots, FA_{N_R}\}$, що визначає структуру нейро-нечіткої моделі NFN .

При використанні першого підходу для розбиття діапазону значень вхідних ознак $[p_{m \min}; p_{m \max}]$ на інтервали вихідний багатовимірний простір ознак p_1, p_2, \dots, p_M ділиться на прямокутні підпростори на основі заздалегідь заданої кількості інтервалів (кількості термів) для кожного атрибута p_m . Однак практичне застосування такого підходу обмежено вибірками $S = \langle P, T \rangle$, що містять інформацію про незначну кількість M ознак p_m . При обробці великих

даних в результаті розбиття діапазону значень вхідних ознак може бути згенеровано занадто велику кількість термів ft_{mr} ознак і, відповідно, нечітких правил, що вимагає істотних витрат пам'яті обчислювальної системи і ускладнює процес синтезу нейро-нечітких моделей на основі отриманих розбиттів інтервалів значень ознак [263].

Для виділення термів ознак широко використовується метод кластеризації даних на основі нечітких c -середніх [45, 47, 59], який дозволяє виділити групи компактно розташованих об'єктів у просторі пошуку. Проте такий підхід також вимагає істотних обчислювальних ресурсів. Крім того, при використанні методу нечітких c -середніх користувач повинен задати кількість кластерів, що генеруються (параметр, який суттєво впливає на результат кластеризації, і як правило, заздалегідь є невідомим). Іншим недоліком такого методу є проблема завдання базової форми генерованих кластерів (як правило, в базовому методі нечітких c -середніх відбувається пошук сферичних кластерів з однаковими дисперсіями по осях ознак. У випадку групування об'єктів в більш складні геометричні тіла необхідно використовувати інші методи, які також вимагають завдання певної кількості параметрів) [45, 47, 59–63].

Таким чином, при автоматизації процесу синтезу нейро-нечітких моделей проблемним є етап виділення термів ft_{mr} ознак (побудови бази правил за наявним набором вхідних даних $S = \langle P, T \rangle$), що визначають кількість нейроелементів в синтезованих моделях. Наявність недоліків відомих підходів до виділення термів ознак обумовлює необхідність розробки нових методів розбиття вхідного набору ознак p_1, p_2, \dots, p_M на підмножини шляхом редукції даних за допомогою видобування продукційних правил.

В наш час для параметричного синтезу (визначення параметрів, що настроюються) діагностичних моделей на основі нейро-нечітких мереж застосовуються різні методи (градієнтні, стохастичні та ін.) [59–63, 204–211, 217–219].

Вище зазначено що, як правило, для налаштування параметрів нейро-нечітких моделей використовуються градієнтні методи. Зокрема, для визначення параметрів функцій належності і функцій, реалізованих в консеквентах правил в моделі ANFIS використовується гібридне правило навчання [217–219, 249–256], при якому кожна ітерація процесу навчання нейро-нечіткої моделі ANFIS виконується в два етапи. На першому етапі на основі даних навчальної вибірки $S = \langle P, T \rangle$ за допомогою методу найменших квадратів відбувається настройка значень параметрів $a_{0r}, a_{1r}, a_{2r}, \dots, a_{Mr}$ функцій $f_r^{(4)}$ (нейроелементів четвертого шару мережі) таким чином, щоб сума відхилень (помилка) між реальними виходами t_q і виходами $t_{NFN}(s_q)$, розрахованими за синтезованою моделлю NFN , була мінімальною. На другому етапі помилка, отримана в результаті виконання першого етапу, передається послідовно від нейрону останнього шару до нейронів першого шару, і за допомогою методу зворотного поширення помилки відбувається обчислення значень параметрів w_{mr} функцій належності $\mu_{mr}^{(1)}$, що реалізуються в нейроелементах першого шару. У нейро-мережах типу Мамдані параметри третього шару визначаються також, як правило, за допомогою градієнтного методу зворотного поширення помилки [217–219, 251–256].

Метод зворотного поширення помилки [57–63, 77–81] відноситься до методів градієнтної оптимізації (є модифікацією методу градієнтного спуску [57–63, 108]) і полягає в поширенні на кожній ітерації обчисленого значення помилки E нейро-нечіткої моделі у напрямку від нейрону останнього шару до нейронів першого шару. Використовуючи відомі значення помилки E нейро-нечіткої моделі, виконується корегування значень параметрів w_{mr} , що настроюються. Для модифікації значень параметрів w_{mr} виконується обчислення значень приростів Δw_{mr} відповідних параметрів таким чином, щоб реалізувати градієнтний спуск у багатовимірному просторі параметрів w_{mr} у напрямку від поточного положення до оптимального (мінімального значення

цільової функції $E = E(\mu_{mr}^{(1)}) = E(\mu_{mr}^{(1)}(w_{mr}))$. Значення приростів Δw_{mr} параметрів w_{mr} обчислюються послідовно для кожного екземпляра s_q вихідної вибірки $S = \langle P, T \rangle$, використовуючи формулу (1.6):

$$\Delta w_{mr} = -\alpha \frac{\partial E(\mu_{mr}^{(1)}(w_{mr}))}{\partial w_{mr}} = -\alpha \frac{\partial E}{\partial \mu_{mr}^{(1)}} \frac{\partial \mu_{mr}^{(1)}}{\partial w_{mr}}, \quad (1.6)$$

де $\alpha \in (0;1)$ – параметр методу, який визначає швидкість руху у напрямку до оптимуму. Після обчислення значень приростів Δw_{mr} відбувається коригування значень параметрів w_{mr} для поточного екземпляра s_q : $w_{mr}(s_q) = w_{mr}(s_q) + \Delta w_{mr}(s_q)$, після чого процедура продовжується для наступного екземпляра s_{q+1} вибірки $S = \langle P, T \rangle$.

Можливі реалізації стохастичного та пакетного градієнтного спуску в методі зворотного поширення помилки [108, 264]. При стохастичному градієнтному спуску значення параметрів w_{mr} коригуються на величину приростів Δw_{mr} відразу після аналізу чергового екземпляра s_q вибірки $S = \langle P, T \rangle$. Ітеративність процедури коригування параметрів w_{mr} для кожного екземпляра вибірки призводить до суттєвих витрат часу при використанні такого підходу. При пакетній реалізації градієнтного спуску функція помилки E визначається для всіх екземплярів s_q вибірки, після чого відбувається коригування значень w_{mr} . Такий підхід працює швидше у порівнянні зі стохастичним градієнтним спуском, проте він більш схильний до зациклення в областях локальних екстремумів, що часто не дозволяє синтезувати нейро-нечіткі моделі, які забезпечують прийнятний рівень помилки.

Враховуючи градієнтний характер цього методу, для можливості його застосування для настройки значень параметрів w_{mr} функцій належності $\mu_{mr}^{(1)}$ необхідно, щоб функції $\mu_{mr}^{(1)}$ були диференційованими. Таким чином, суттєвими

недоліками методу зворотного поширення помилки, який широко застосовується для побудови нейромережових діагностичних моделей, є досить повільна збіжність [57–63, 108, 264], особливо при обробці великих даних, а також схильність до зациклення в областях локальних екстремумів.

Для синтезу нейромережових моделей в наш час застосовуються методи на основі глибокого навчання (глибокого структурованого навчання, ієрархічного навчання), що включає в себе набір методів машинного навчання, які використовують багатошарову систему фільтрів для ієрархічного видобування інформативних атрибутів [64, 91, 92, 100, 148, 210, 241, 246]. Аналогічно деяким іншим методам машинного навчання, на кожній ітерації глибокого навчання налаштовувані параметри w_{mr} нейромережової моделі *NFN* змінюються і уточнюються, як правило, за допомогою методу градієнтного спуску [108, 210, 241, 246, 264].

Глибоке навчання використовується для синтезу складних багатошарових нейромережових моделей, які містять декілька шарів, що реалізують нелінійні функції. Тому такі методи дозволяють синтезувати нейромережові моделі з великою кількістю ієрархічно пов'язаних нейроелементів, внаслідок чого синтезовані моделі є дуже громіздкими та складними для розуміння (характеризуються низькою інтерпретовністю). Перевагою таких методів у порівнянні з іншими методами машинного навчання [14, 57–62], застосовуваними для синтезу нейромережових моделей, є те, що методи глибокого навчання не вимагають участі користувача в процесі видобування ознак для побудови розпізнавальних моделей [92, 100, 148, 210, 241, 246]. Ознаки конструюються автоматично в процесі навчання багатошарової нейромоделі, при чому на перших шарах моделі синтезуються більш прості ознаки, що характеризують дрібні деталі об'єктів, а виходи далеких шарів моделі відповідають більш складним ознаками, які агрегують, узагальнюють в собі атрибути попередніх шарів. Таким чином формується

багатошарова модель з різними рівнями абстракції на кожному шарі. Глибоке навчання дозволяє комбінувати методи навчання без учителя та з учителем.

В даний час запропоновано різні глибокі методи для навчання нейронечітких мереж. У методі навчання нечітких глибоких мереж переконань (fuzzy deep belief network), запропонованому в [265] для розв'язання завдання класифікації, була досягнута точність близько 70% на різних наборах даних. У запропонованому методі [265] забезпечується інтеграція нечіткої логіки і глибоких нейронних мереж, однак витяг нечітких правил не передбачається, хоча і задаються функції μ_{mr} , які визначають належність кожного вхідного атрибуту p_m кожному можливому класу вихідного параметра t . Як модель використовується тришарова глибока нейронна мережа. Таким чином синтезується модель, яка забезпечує можливість класифікації з прийнятною точністю, проте не дозволяє пояснювати прийняті рішення (синтезована модель складається з великої кількості нейроелементів, є досить складною і, відповідно, характеризується низькою інтерпретовністю). В [266] запропоновано модифікацію моделей на основі LSTM нейронних мереж шляхом об'єднання підходів на основі нечіткої логіки та глибокого навчання. Запропоновані моделі застосовувалися для виявлення візуальної невідповідності у роботизованій хірургії та дозволили підвищити точність розпізнавання на 35%. Відзначимо, що для глибокого навчання потрібні великі обсяги даних і великі обчислювальні потужності комп'ютерної системи, що зумовило розвиток і широке поширення методів глибокого навчання в даний час. Проте в наслідок високої складності синтезованих багатошарових нейромоделей, які характеризуються великою кількістю параметрів w_{mr} , що настроюються, використання методів глибокого навчання пов'язано з суттєвими витратами часу на синтез моделей.

Практичні завдання, що вирішуються за допомогою багатошарових нейромереж, які навчають за допомогою глибокого навчання, як правило, пов'язані з обробкою звукових або графічних образів (комп'ютерний зір,

розпізнавання мови та ін.). Для діагностування на основі наборів прецедентів такі методи навчання не є досить ефективними, особливо якщо вхідні набори даних $S = \langle P, T \rangle$ складаються з невеликої кількості ознак або ознаки в вибірках $S = \langle P, T \rangle$ не є ієрархічно взаємопов'язаними. Тому для синтезу інтерпретованих діагностичних моделей на основі нейро-нечітких мереж методи глибокого навчання доцільно використовувати лише в тому випадку, коли вхідні дані характеризуються дуже великим обсягом взаємозалежних ознак, що описують звукові або графічні образи, і не потрібно будувати моделі з високою інтерпретованістю.

Недоліком класичних нейро-нечітких моделей і методів їх побудови (параметричного синтезу) на основі градієнтної оптимізації [108, 210, 241, 246, 264] є необхідність залучення експертів у прикладних областях для формування правил і завдання типів функцій належності, які визначають структуру мережі, що знижує рівень автоматизації процесу синтезу таких моделей. Це, у свою чергу, може привести до побудови нейро-нечітких мереж, які не будуть спроможними до узагальнення вихідних діагностичних даних [217–219, 249–256]. Вище відзначено, що відомі методи нечіткого розбиття вхідного набору ознак p_1, p_2, \dots, p_M на підмножини [45, 47, 59, 263], які дозволяють автоматизувати етап структурного синтезу нейро-нечітких моделей, також мають певні недоліки. Тому в деяких випадках використовується гібридний підхід із застосуванням адаптивних нейро-нечітких систем, в яких формування нечітких правил (структурний синтез) і налаштування параметрів нейро-нечіткої моделі NFN (параметричний синтез) відбуваються в процесі навчання на основі даних s_q навчальної вибірки $S = \langle P, T \rangle$ [263–266]. Такі методи побудови (структурно-параметричного синтезу) нейро-нечітких моделей, як правило, є досить складними, вимагають значних обчислювальних і часових ресурсів та забезпечують виконання етапів формування бази правил (завдання дискретної оптимізації) і налаштування функцій належності мережі (завдання неперервної оптимізації). Для розв'язання таких завдань широко

використовуються еволюційні методи, які є методами стохастичної оптимізації і не висувають вимог до виду цільової функції.

Варто відзначити, що еволюційні методи дозволяють розв'язувати не тільки завдання структурно-параметричного синтезу (одночасного формування нечітких правил, які визначають структуру мережі, і налаштування параметрів моделі), але і окремо завдання структурного і параметричного синтезу нейро-нечітких моделей [204–211, 217–219, 263]. До таких методів відноситься множина випадково спрямованих евристичних методів (генетичні алгоритми, еволюційні стратегії, еволюційне програмування та ін. [204–211]), заснованих на стохастичному підході та на аналогіях з природними еволюційними процесами [204–211, 264]. Еволюційні методи в процесі оптимізації на кожній t -й ітерації працюють з множиною рішень $R^{(t)} = \{\chi_1^{(t)}, \chi_2^{(t)}, \dots, \chi_{N_\chi}^{(t)}\}$, кожне з яких представляє деяку точку в вихідному просторі атрибутів розв'язуваної задачі. В процесі еволюційної оптимізації особини $\chi_k^{(t)}$ отримують можливість генерувати нові рішення $\chi_k^{(t+1)}$ шляхом застосування еволюційних операторів схрещування та мутації, а також можливість бути відібраними для входження в нову популяцію $R^{(t+1)}$, виходячи із значення своєї цільової функції $E(\chi_k^{(t)})$. Для можливості застосування еволюційних методів для вирішення практичних завдань діагностування необхідно задати генетичне подання вихідних даних (закодувати оптимізовані параметри цільової функції) і цільову функцію для оцінювання якості рішень $\chi_k^{(t)}$ на кожній ітерації [204–211]. Методи еволюційного пошуку за задану кількість ітерацій $Iter$ обробляють $Iter \cdot N_\chi$ контрольних точок (де N_χ – кількість рішень, що обробляються на кожній ітерації стохастичного пошуку). Тому обчислювальна складність $O(Iter \cdot N_\chi)$ такого підходу не залежить безпосередньо від розміру вхідної вибірки даних $S = \langle P, T \rangle$.

Можливість роботи з множиною рішень $R^{(t)} = \{\chi_1^{(t)}, \chi_2^{(t)}, \dots, \chi_{N_\chi}^{(t)}\}$ на кожній ітерації пошуку за допомогою застосування еволюційних операторів відбору, схрещування та мутації, заснованих на стохастичному підході, дозволяє еволюційним методам більш детально досліджувати простір пошуку, а також виходити з областей локальних екстремумів. Рішення (точки в просторі пошуку), знайдені за допомогою таких методів, не можуть вважатися глобальними оптимумами в силу використання стохастичного підходу [204–211, 264]. Проте при розв’язанні практичних завдань діагностування часто необхідно знайти рішення (синтезувати діагностичну модель), яке забезпечує прийнятні показники якості діагностування (прийнятну точність діагностування), що дозволяє застосовувати еволюційні методи для обробки діагностичних даних.

Іншим недоліком еволюційних методів є їх висока ітеративність, і, відповідно, високі вимоги до обчислювальних ресурсів комп’ютеру та часу, що витрачається на оптимізаційний процес. Великі витрати часу й обчислювальних ресурсів також пов’язані з необхідністю повторного запуску еволюційної оптимізації у випадку невдалого завершення попереднього процесу (коли рішення, яке задовольняє заданим критеріям якості, не знайдено). Це істотно ускладнює застосування еволюційних методів на практиці, особливо при обробці вибірок великої розмірності [204–211, 264].

Для скорочення часу стохастичної оптимізації за допомогою еволюційного підходу застосовують паралельні реалізації еволюційних методів [204, 206, 211, 267–269]. Паралельні методи використовують генетичні методи для вирішення задачі оптимізації шляхом розподілу множини контрольних точок (рішень) $R^{(t)} = \{\chi_1^{(t)}, \chi_2^{(t)}, \dots, \chi_{N_\chi}^{(t)}\}$ серед наявного набору обчислювальних процесорів [267–269]. Так в однопопуляційних генетичних методах на основі моделі «ведучий-ведений» (single-population master-slave GA, master-slave GA), один процесор є головним (master), який керує процесом еволюційного пошуку, а обчислення цільової функції виконується на підлеглих (slaves) процесорах

[267–269]. При використанні острівного генетичного методу (island GA) виконується розбиття популяції $R^{(t)} = \{\chi_1^{(t)}, \chi_2^{(t)}, \dots, \chi_{N_\chi}^{(t)}\}$ на декілька підпопуляцій, які обмінюються особинами $\chi_k^{(t)}$ з деякою заданою частотою міграцій. Ієрархічні гібридні еволюційні моделі є поєднанням острівної моделі генетичного пошуку з моделлю «ведучий-ведений», при цьому на верхньому рівні використовується острівна модель, на нижніх рівнях може застосовуватися модель «ведучий-ведений». Паралельні методи дозволяють прискорити процес пошуку рішення, використовуючи декілька обчислювальних вузлів паралельної системи. Проте використання, як правило, єдиних стратегій пошуку на різних підпопуляціях (вузлах обчислювальної системи) так само, як і при послідовних реалізаціях еволюційних методів, в деяких випадках не дозволяє вирішити проблему передчасної збіжності (у випадку знаходження на деякій ітерації областей локальних оптимумів відбувається зациклення в таких областях та спостерігається подальше зосередження рішень навколо них) та забезпечити пошук в різних областях розташування локальних екстремумів. Не дивлячись на наявність механізмів виходу з локальних екстремумів (наприклад, використання оператора мутації в методах еволюційного пошуку або процедури перезапуску агентів у агентно-орієнтованих методах обчислювального інтелекту) концентрування деякої кількості рішень (пробних точок) навколо областей локальних екстремумів тим не менш спостерігається і на наступних ітераціях пошуку. Це знижує ефективність пошуку (досліджуються одні і ті ж області простору ознак), збільшує час його виконання на обчислювальній машині, і, в деяких випадках, не дозволяє знайти прийнятне рішення. Крім того, ефективність використання паралельних еволюційних методів суттєво залежить від вибору параметрів частоти обміну інформацією між вузлами паралельної системи. Тому при невірному завданні параметрів паралельні методи можуть працювати довше у порівнянні з послідовними методами, що пов'язано з необхідністю витрат часу

на пересилання даних між процесами та часу на синхронізацію роботи процесів.

Тому для усунення зазначених недоліків необхідно прискорити процес еволюційної оптимізації шляхом розробки нових високопродуктивних еволюційних методів, які дозволять скоротити час синтезу і навчання нейронечітких діагностичних моделей за множинами прецедентів великої розмірності і збільшити практичний поріг обмежень розмірності даних при побудові систем діагностування та неруйнівного контролю якості.

1.8 Висновки за розділом 1 та постановка завдань дослідження

Розглянуто стан проблеми діагностування на основі даних. Надано постановку завдання синтезу діагностичних моделей. Проаналізовано властивості та характеристики навчальних вибірок вхідних даних, що використовуються в процесі побудови моделей об'єктів діагностування. Відзначено, що наборам навчальних даних, як правило, властиві наявність пропущених і суперечливих значень, різні типи вхідних атрибутів і вихідного параметру об'єктів вибірки, шумів, неструктурований характер даних, великі обсяги надлишкових даних та інші характеристики, які суттєво уповільнюють, ускладнюють, а в деяких випадках і роблять неможливим застосування існуючих методів обробки діагностичних даних. Наявність зазначених недоліків обумовлює необхідність розробки нових методів і засобів обробки даних, здатних підвищити швидкість обробки інформації, а також поліпшити узагальнювальні та апроксимаційні властивості діагностичних моделей, синтезованих на основі наявних наборів даних.

Проведено аналіз методів попередньої обробки даних для синтезу діагностичних моделей. Відзначено, що при вирішенні практичних завдань

діагностування може виникнути потреба обробки даних, які містять велику кількість пропущених значень, що ускладнює застосування відомих методів і обумовлює необхідність розробки нових методів обробки даних з пропущеними значеннями на основі видобування асоціативних правил. Встановлено, що процес редукції даних при діагностуванні пов'язаний з необхідністю оцінювання інформативності ознак. Однак відомі критерії оцінювання індивідуальної і групової інформативності, як правило, ґрунтуються на припущенні про те, що ознаки вибірки є незалежними величинами, інші критерії дозволяють встановити ступінь тісноти зв'язку випадкових величин тільки лінійного виду, деякі засновані на припущенні про нормальність розподілу випадкових величин, що істотно ускладнює застосування таких критеріїв на практиці і викликає потребу розробки нових критеріїв оцінювання індивідуальної та групової інформативності ознак. Обґрунтовано доцільність розробки нового методу відбору інформативних ознак, заснованого на стохастичному підході та високопродуктивних обчисленнях. Показано, що істотні витрати часу при виконанні обчислювальних процедур в процесі редукції даних шляхом видобування продукційних правил ускладнюють застосування існуючих методів при вирішенні практичних завдань діагностування, що обумовлює необхідність модифікації існуючих і створення нових методів і засобів побудови наборів правил на основі еволюційних обчислень.

Розглянуто різні типи моделей, які можуть використовуватися для розв'язання завдань діагностування. В якості базису для синтезу діагностичних моделей запропоновано вибрати моделі на основі нейронних мереж, які характеризуються високими апроксимаційними та узагальнювальними здібностями, в силу природного паралелізму можуть бути легко реалізовані на паралельних обчислювальних системах, що дозволяє істотно спростити процес діагностування на основі таких моделей. Проаналізовано різні види нейронних мереж. Встановлено, що в якості діагностичних моделей на основі нейронних

мереж ефективно можуть застосовуватися нейро-нечіткі мережі, що являють собою нелінійні моделі, які є легкими у використанні та розумінні, а також, на відміну від статистичних та регресійних моделей є універсальними апроксиматорами, що дозволяє їх використовувати для відновлення складних нелінійних залежностей різних вибірок даних. Відзначено, що на відміну від багатошарових персептронів, які являють собою моделі чорного ящика (за якими користувач не може пояснити, яким чином обчислюється значення вихідного параметра за заданим набором вхідних ознак), нейро-нечіткі мережі є більш доступними до розуміння експертами в прикладних областях, дозволяють генерувати набори легко доступних та інтерпретованих продукційних правил, крім того, такі моделі дозволяють більш ефективно обробляти набори, що характеризуються невизначеністю та суперечливістю даних.

Проаналізовано процес і методи синтезу нейро-нечітких діагностичних моделей. Визначено, що для синтезу нейро-нечітких мереж ефективно можуть застосовуватися еволюційні методи, які є методами стохастичної оптимізації та не висувають вимог до виду цільової функції і дозволяють вирішувати завдання структурного та параметричного синтезу нейро-нечітких моделей. Показано, що суттєвим недоліком еволюційних методів є їх висока ітеративність, і, відповідно, високі вимоги до обчислювальних ресурсів комп'ютера і часу, що витрачається на оптимізаційний процес. Обґрунтовано необхідність прискорення процесу еволюційної оптимізації шляхом розробки нових високопродуктивних еволюційних методів, які дозволять скоротити час синтезу і навчання нейро-нечітких діагностичних моделей за множинами прецедентів великої розмірності і збільшити практичний поріг обмежень розмірності даних при побудові систем діагностування та неруйнівного контролю якості.

Метою дисертаційної роботи є розроблення та дослідження методів високопродуктивного оброблення даних для синтезу діагностичних моделей, які поєднують принципи інтелектуальних та паралельних обчислень для

підвищення швидкості процесу побудови діагностичних моделей, збільшення їх інтерпретовності та узагальнювальних можливостей.

Для досягнення поставленої мети необхідно розв'язати такі задачі:

- виконання аналізу та дослідження процесу синтезу діагностичних моделей на основі нейро-нечітких мереж;
- розробка нових методів видобування продукційних правил на основі дерев розв'язків, негативного відбору та асоціативних правил для синтезу діагностичних моделей;
- розробка паралельного методу видобування знань при обробці великих вибірок даних;
- розробка нових критеріїв оцінювання індивідуальної та групової інформативності ознак;
- розробка методу редукції даних, заснованого на стохастичному підході та високопродуктивних обчисленнях;
- розробка методу синтезу нейро-нечітких діагностичних моделей;
- розробка методу донавчання діагностичних нейро-нечітких моделей;
- проведення експериментального дослідження розроблених методів обробки даних та синтезу діагностичних моделей.

Таким чином, у роботі розв'язується науково-прикладна проблема розроблення та дослідження методів синтезу діагностичних моделей, які поєднують принципи інтелектуальних та паралельних обчислень, що дозволяє підвищити швидкість процесу побудови діагностичних моделей, збільшити їх інтерпретовність та узагальнювальні можливості.

Список використаних джерел у цьому розділі наведено у повному списку використаних джерел під номерами [1–269].

2 ВИДОБУВАННЯ ЗНАНЬ ДЛЯ ПОБУДОВИ ДІАГНОСТИЧНИХ МОДЕЛЕЙ НА ОСНОВІ ІНТЕЛЕКТУАЛЬНИХ ОБЧИСЛЕНЬ

Синтез моделей прийняття рішень при розробці інтелектуальних систем технічного діагностування, неруйнівного контролю якості промислових виробів і систем неінвазивного діагностування в медицині пов'язаний з необхідністю оброблення вибірок даних, що містять інформацію про значення вхідних і вихідних характеристик множини екземплярів [6–10, 108, 109].

Однак вибірки даних, що описують результати вимірювань характеристик реальних технічних об'єктів і процесів можуть містити дубляж інформації, зокрема, надлишкові для прийняття рішень ознаки та екземпляри [126–132, 195–203]. Крім того, можлива наявність пропусків у даних (відсутність значень деяких з виміряних характеристик для деяких екземплярів), а також ситуації, при яких у вихідній вибірці порушена частота класів щодо генеральної сукупності (вбірка може не містити достатнє число екземплярів визначеного класу), або кількість екземплярів одного класу істотно відрізняється від кількості екземплярів іншого класу (при традиційному навчанні екземпляри одного класу можуть подавляти екземпляри іншого класу) [126–137, 164–168, 188–194].

Наведені вище проблеми, що виникають, як правило, при обробці даних, отриманих у результаті вимірювань характеристик реальних технічних і медичних об'єктів, ускладнюють і в деяких випадках унеможливають застосування градієнтних методів оптимізації [106, 108, 264], традиційно використовуваних при побудові моделей прийняття рішень для неруйнівного контролю якості, оскільки такі методи вимагають значних витрат часу і апаратних ресурсів комп'ютера при визначенні структури та параметрів синтезованих моделей, передбачають обчислення значень похідних цільової функції, істотно залежать від вибору початкової точки в просторі пошуку та

можуть зациклюватися в локальних оптимумах. Це, у свою чергу, обумовлює необхідність розробки методів синтезу моделей контролю якості, вільних від зазначених недоліків.

Відомі методи синтезу моделей для технічного та медичного діагностування [75–89, 133–141, 164–187] на основі нейронних мереж, нечіткої логіки, дерев розв'язків, асоціативних правил, імунних систем окремо вирішують лише деякі з розглянутих проблем, не дозволяючи в комплексі усунути усі відзначені недоліки.

Як відзначено вище, процес побудови моделей прийняття рішень на основі нейро-нечітких мереж пов'язаний з необхідністю видобування правил із заданих вибірок даних.

З метою усунення проблем надмірності та неповноти інформації, а також проблеми порушення частоти класів при обробленні різних вибірок вихідних даних у процесі побудови діагностичних моделей прийняття рішень у цьому розділі пропонується видобувати продукційні правила шляхом застосування різних методів і засобів штучного інтелекту [75–89, 133–141, 164–187]: дерев розв'язків [75, 76, 88, 89, 270–273], негативного відбору [164–187], асоціативних правил [133–141].

2.1 Видобування знань на основі дерев розв'язків

Видобування правил на основі дерев розв'язків може дозволити виділити найбільш цінні екземпляри, ранжувати ознаки за значущістю і, отже, усунути деяку надмірність наявної інформації.

Однак відомі методи синтезу дерев розв'язків [75, 76, 88, 89, 271–273] передбачають використання "жадібного" підходу, що не дозволяє в процесі побудови таких моделей повторно розглядати ознаки p_m , по яких уже було

виконано розбиття. Це може привести до низьких узагальнювальних властивостей синтезованої моделі внаслідок її складності, а, отже, до надлишкової кількості правил, видобутих з неї, що зробить систему правил більш громіздкою та менш інтерпретовною.

Тому для побудови дерев розв'язків пропонується [274–278] використовувати інтелектуальний стохастичний пошук [204–211, 264, 267–269], що дозволяє досліджувати різні області пошукового простору та не використовує жадібну стратегію.

У запропонованому стохастичному методі синтезу дерев розв'язків [274] використовується інформація про інформативність ознак, складність синтезованого дерева, а також точність його розпізнавання, що дозволяє на початковому етапі формувати множину деревоподібних структур, які характеризуються простою ієрархією та невисокою помилкою розпізнавання, у процесі пошуку створювати нові множини рішень з урахуванням інформації про значущість ознак та інтерпретовність генерованих дерев, що, у свою чергу, забезпечує можливість побудови дерева розв'язків з невеликою кількістю елементів (вузлів і зв'язків між ними) і прийнятною точністю розпізнавання, а також видобування на його основі найбільш цінних екземплярів.

На етапі ініціалізації в розробленому стохастичному методі синтезу дерев розв'язків [274–278] генерується початкова множина рішень $R^{(0)} = \{\chi_1^{(0)}, \chi_2^{(0)}, \dots, \chi_{N_\chi}^{(0)}\}$, де N_χ – кількість рішень у множині $R^{(0)}$.

Кожне k -те рішення χ_k являє собою структуру, що відповідає деякому дереву розв'язків (рис. 2.1). На рис. 2.1 позначення $T = t_a$ відповідає значенню t_a вихідного параметра T при проході від кореня дерева до одного з його листів (кінцевих вузлів, що містять значення вихідного параметра при виконанні умов, які знаходяться у вузлах-батьках, розташованих вище за ієрархією від поточного листа); d_{ab} – b -й вузол a -го рівня синтезованого дерева розв'язків χ_k ; p_{mab} – ознака-перевірка у вузлі d_{ab} ; p_{TRab} – граничне значення ознаки-перевірки вузла d_{ab} .

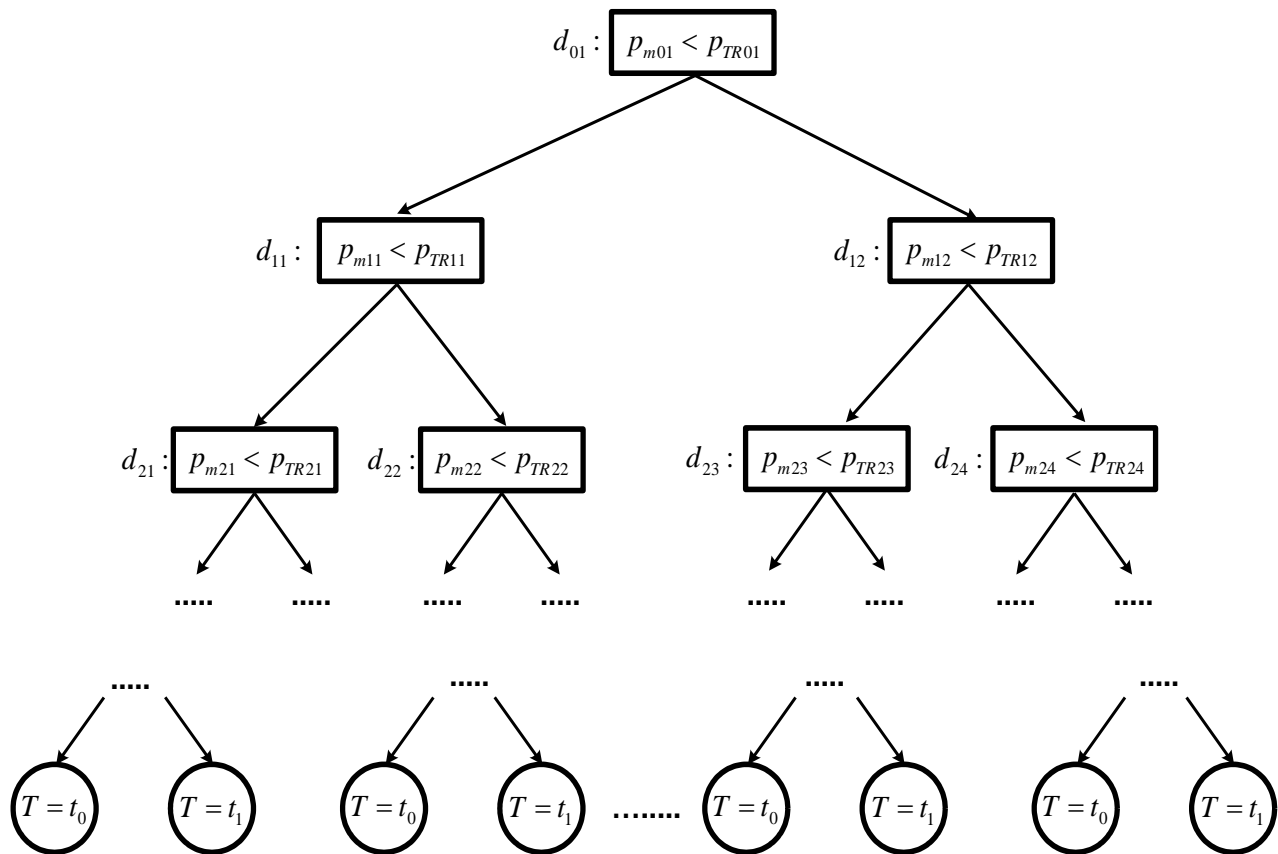


Рисунок 2.1 – Схематичне подання структури χ_k
при синтезі дерев розв'язків

Як видно з рис. 2.1, при синтезі кожного дерева розв'язків χ_k необхідно визначати його структуру, що являє собою набір взаємозалежних вузлів виду (2.1):

$$d_{ab} = \langle p_{mab}, p_{TRab}, d_{(a+1)(2b-1)}, d_{(a+1)(2b)} \rangle, \quad (2.1)$$

які містять таку інформацію:

- ознака p_{mab} , по якій виконується розбиття,
- граничне значення p_{TRab} ознаки p_{mab} ;
- посилання на лівого $d_{(a+1)(2b-1)}$ та правого $d_{(a+1)(2b)}$ нащадків.

Отже, для побудови дерева розв'язків χ_k необхідно сформулювати множину взаємозалежних вузлів-перевірок d_{ab} , визначивши для кожного з них ознаку-перевірку p_{mab} та її граничне значення p_{TRab} .

При виборі ознаки-перевірки p_{mab} для вузла d_{ab} будемо використовувати апріорну інформацію про значущість ознак V_m . Оскільки дерева розв'язків ефективно застосовуються, як правило, для розв'язання задач розпізнавання, що характеризуються кінцевою кількістю класів вихідного параметра T , для оцінювання інформативності V_m ознак доцільно використовувати характеристики, які дозволяють оцінювати значущість ознаки p_m стосовно вихідного параметра T , що приймає дискретні значення t_q з кінцевої множини. Як такі характеристики можуть бути використані такі критерії [45, 47, 48, 57–63]: ентропія ознаки $VE(p_m)$ і теоретико-інформаційний критерій $VT(p_m)$.

Ентропія ознаки $VE(p_m)$ – критерій, що визначає ступінь невизначеності стану об'єкта [45, 47, 48, 57–63], розраховується по формулі (2.2):

$$VE(p_m) = - \sum_{n=1}^{N_{\text{int}}(p_m)} \left(\rho(p_{mn}) \sum_{l=1}^{N_{\text{int}}(T)} \rho(p_{mn}, T_l) \log_2 \rho(p_{mn}, T_l) \right), \quad (2.2)$$

де $\rho(p_{mn}) = \frac{N(p_{mn})}{Q}$ – імовірність того, що значення ознаки p_m екземплярів вибірки S потрапить до n -го інтервалу діапазону її зміни;

$N(p_{mn})$ – кількість екземплярів вибірки S , значення m -ї ознаки яких, належать n -му інтервалу діапазону її зміни;

$N_{\text{int}}(p_m)$ – кількість інтервалів, на які розбивається діапазон значень m -ї ознаки p_m ;

$N_{\text{int}}(T)$ – кількість інтервалів, на які розбивається діапазон значень вихідного параметра T ;

$\rho(p_{mn}, T_l) = \frac{N(p_{mn}, T_l)}{N(p_{mn})}$ – умовна імовірність того, що значення вихідного

параметра T потрапить у l -й інтервал T_l за умови, що m -а ознака p_m потрапить у n -й інтервал p_{mn} ;

$N(p_{mn}, T_l)$ – кількість екземплярів вибірки S , значення вихідного параметра T яких належать l -му інтервалу діапазону його зміни T_l за умови, що значення їх m -ї ознаки належить n -му інтервалу p_{mn} .

Теоретико-інформаційний критерій $VT(p_m)$ – передбачає використання кількості інформації, що одержує система в процесі розпізнавання об'єктів у результаті використання оцінюваної ознаки (2.3):

$$VT(p_m) = \sum_{l=1}^{N_{\text{int}}(T)} \sum_{n=1}^{N_{\text{int}}(p_m)} \rho(p_{mn}, T_l) \log_2 \frac{\rho(p_{mn}, T_l)}{\rho(p_{mn})\rho(T_l)}, \quad (2.3)$$

де $\rho(T_l)$ – імовірність того, що значення вихідного параметра T потрапить у l -й інтервал T_l діапазону зміни його значень.

Однак застосування таких критеріїв передбачає, що відомими є всі значення всіх екземплярів у навчальній вибірці S . Проте це є не завжди можливим при вирішенні практичних задач діагностування і керування якістю продукції (це обумовлено можливими проблемами при вимірюванні параметрів деяких реальних технічних об'єктів або процесів). Крім того, у випадку, якщо оцінювана ознака p_m не є дискретною, а приймає значення з певного діапазону $p_m \in [p_{m \min}; p_{m \max}]$, то при застосуванні таких критеріїв виникає проблема вибору кількості інтервалів $N_{\text{int}}(p_m)$, на які необхідно розбити діапазон значень ознаки p_m . Неправильний вибір значення величини $N_{\text{int}}(p_m)$ може призвести до некоректних результатів оцінювання інформативності ознак за описаними вище критеріями.

Тому у деяких випадках, зокрема, при великій кількості ознак p_m , що приймають числові значення з деякого інтервалу, пропонується

використовувати наступний підхід до оцінювання індивідуальної значущості V_m . Оцінювати інформативність ознак будемо виходячи з їхньої значущості для визначення границь кластерів – груп компактно розташованих екземплярів у ознаковому просторі. Кластерами Cl_c будемо вважати екземпляри вибірки S з однаковим значенням вихідного параметру $T = T_1$. Іншим підходом для пошуку груп компактно розташованих екземплярів є застосування відомих методів кластерного аналізу [57–63, 97, 130–132].

Будемо вважати, що ознака p_m є тим важливішою для кластера Cl_c ($c = 1, 2, \dots, N_{cl}$), чим меншою є ширина розкиду σ_{mc} її значень у цьому кластері, розрахована за формулою (2.4):

$$\sigma_{mc} = \sqrt{\sum_{q=1}^{N(Cl_c)} (p_{mq} - \overline{p_{mc}})^2}, \quad (2.4)$$

де p_{mq} – значення m -ї ознаки q -го екземпляра, що входить у c -й кластер;

$\overline{p_{mc}}$ – середнє значення m -ї ознаки p_m в c -му кластері;

$N(Cl_c)$ – кількість екземплярів c -го кластера Cl_c .

Потім найбільш значущій ознаці c -го кластера (ознаці з мінімальним значенням величини σ_{mc}) будемо ставити у відповідність найбільше значення рангу $R\sigma_{mc} = M$, наступній по зростанню величини σ_{mc} ознаці привласнимо значення $R\sigma_{mc} = M - 1$ і т.д. При однакових значеннях величини σ_{mc} ознакам ставляться у відповідність середні значення рангів $R\sigma_{mc}$. Ознакам, що характеризуються низькими значеннями індивідуальної інформативності для екземплярів c -го кластера ($\sigma_{mc} < \sigma_{mc \min}$), ставиться у відповідність нульове значення величини $R\sigma_{mc}$: $R\sigma_{mc} = 0$.

Значення загального рангу $R\sigma_m$ m -ї ознаки p_m по всіх N_{cl} кластерах визначимо як суму значень рангів $R\sigma_{mc}$ за формулою (2.5):

$$R\sigma_m = \sum_{c=1}^{N_{cl}} R\sigma_{mc}. \quad (2.5)$$

Оцінку індивідуальної інформативності V_m m -ї ознаки визначимо за формулою (2.6):

$$V_m = \frac{R\sigma_m}{\max_{n=1,2,\dots,M} \{R\sigma_n\}}. \quad (2.6)$$

Таким чином, ознака з максимальним значенням рангу $R\sigma_m$ є найбільш інформативною і характеризується одиничним значенням критерію V_m . Використання запропонованого критерію (2.6) дозволяє ранжувати ознаки, виходячи з їхньої значущості для опису границь компактного розташування екземплярів, що, у свою чергу, дозволяє оцінювати індивідуальну інформативність ознак у вибірках, в яких деякі екземпляри містять пропущені значення ознак або вихідного параметра.

Після оцінювання інформативності V_m кожної ознаки p_m вибірки S відбувається формування дерев χ_k у вигляді відповідних структур даних. Ознаки p_m з високими оцінками індивідуальної інформативності V_m є більш значущими (істотно впливають на вихідний параметр T), отже, у запропонованому методі такі ознаки будуть мати велику імовірність вибору як ознаки-перевірки p_{mab} для відповідного вузла d_{ab} .

Нехай оцінка індивідуальної інформативності m -ї ознаки p_m дорівнює V_m . Тоді нормована оцінка індивідуальної інформативності ознак V_{m_norm} у вибірці S може бути розрахована за формулою (2.7):

$$V_{m_norm} = \frac{V_m - V_{\min}}{V_{\max} - V_{\min}}, \quad (2.7)$$

де V_{\min} і V_{\max} – мінімальне і максимальне значення інформативності V_m ознак p_m у вибірці S , відповідно.

Вибір ознаки p_m для використання у вузлі-перевірці d_{ab} будемо виконувати, виходячи зі значення величини V_{m_norm} . Для цього будемо послідовно переглядати ознаки p_1, p_2, \dots, p_M і порівнювати значення величини V_{m_norm} з $rand[0;1]$ – випадково згенерованим числом в інтервалі $[0; 1]$. У випадку, якщо виконується умова (2.8)

$$V_{m_norm} \geq rand[0;1], \quad (2.8)$$

ознака p_m вважається такою, що добре розподіляє екземпляри на класи, і включається до поточного вузла d_{ab} дерева розв'язків χ_k як ознака-перевірка.

Далі для ознаки-перевірки p_{mab} у вузлі d_{ab} виконується визначення граничного значення p_{TRab} . Для цього розраховуються значення помилки розпізнавання E_{ab} екземплярів S_{ab} , що попадають у вузол d_{ab} , при різних значеннях $p_{TRab} \in [p_{mab\min}; p_{mab\max}]$, і вибирається таке значення p_{TRab} , при якому значення помилки розпізнавання E_{ab} буде найменшим. У випадку, якщо знайдене значення p_{TRab} , при якому помилка розпізнавання знаходиться в припустимих межах $E_{ab} < E_{TR}$, тоді вважається, що ознака p_{mab} при граничному значенні p_{TRab} дозволяє здійснювати прийнятне розбиття множини екземплярів S_{ab} на класи t_0 і t_1 , отже, її нащадками будуть вузли, що являють собою листи дерева розв'язків χ_k – кінцеві вузли, що містять значення вихідного параметра $T = t_0$ і $T = t_1$. Якщо в результаті розбиття $p_{mab} < p_{TRab}$ в одну з частин дерева увійдуть екземпляри S_{ab} з єдиним значенням вихідного параметра (наприклад, $T = t_1$), то нащадок, що відповідає

даній умові, стає листом, і розбиття продовжується тільки для другого нащадка вузла d_{ab} .

Формування дерева розв'язків χ_k продовжується доти, поки не буде досягнуто прийнятної точності розпізнавання ($E < E_{\min}$) або інших критеріїв, що характеризують складність дерева (досягнення максимальне припустимої кількості вузлів, рівнів, гілок і т.п.). Аналогічним чином на етапі ініціалізації запропонованого методу формується N_χ дерев розв'язків χ_k .

Потім виконується оцінювання якості синтезованих дерев розв'язків χ_k , $k = 1, 2, \dots, N_\chi$. Для цього пропонується використовувати цільову функцію $G = G(\chi_k)$, що враховує інтерпретовність дерева $Int(\chi_k)$ і його розпізнавальні властивості (помилку розпізнавання $E(\chi_k)$), і може бути визначена за формулою (2.9):

$$G(\chi_k) = \gamma_1 Int(\chi_k) + \gamma_2 E(\chi_k), \quad (2.9)$$

де γ_1 і γ_2 – коефіцієнти, що дозволяють врахувати важливість критеріїв $Int(\chi_k)$ та $E(\chi_k)$, відповідно.

Для оцінювання інтерпретовності $Int(\chi_k)$ дерев розв'язків пропонується використовувати такі критерії:

- ширина дерева – може бути визначена як кількість його гілок $N_{branch}(\chi_k)$ або кількість вузлів $N_{node}(\chi_k) = N_{branch}(\chi_k) + 1$;
- глибина дерева – визначається як кількість його рівнів $N_{level}(\chi_k)$;
- гіллястість дерева $Br(\chi_k)$ – пропонується обчислювати за формулою (2.10) як відношення кількості вузлів $N_{node}(\chi_k)$ дерева χ_k до максимально можливої кількості вузлів дерева глибини $N_{level}(\chi_k)$:

$$Br(\chi_k) = \frac{N_{node}(\chi_k)}{\max node(N_{level}(\chi_k))}, \quad (2.10)$$

де $\max node(N_{level}(\chi_k))$ – максимально можлива кількість вузлів дерева χ_k глибини $N_{level}(\chi_k)$ – величина, що може бути визначена за формулою (2.11):

$$\max node(N_{level}(\chi_k)) = \sum_{c=1}^{N_{level}(\chi_k)} 2^{c-1} = 2^{N_{level}(\chi_k)} - 1; \quad (2.11)$$

– узагальнення рішень $Gener(\chi_k)$ – відношення кількості листів (вузлів-рішень) $N_{leaf}(\chi_k)$ дерева χ_k до кількості екземплярів Q навчальної вибірки S (2.12):

$$Gener(\chi_k) = \frac{N_{leaf}(\chi_k)}{Q}; \quad (2.12)$$

де $N_{leaf}(\chi_k)$ – кількість листів (вузлів-рішень) дерева χ_k ;

– внутріштова відстань $Idist(\chi_k)$ між екземплярами вибірки, які потрапили в конкретний лист (екземплярами, що відповідають конкретним умовам, поданим у вигляді шляхів від кореня дерева до його листів) – чим менше ця відстань, тим вищою є компактність рішень у відповідних листах, і, отже, тим кращим є розбиття за допомогою дерева χ_k . Критерій $Idist(\chi_k)$ пропонується обчислювати за формулою (2.13):

$$Idist(\chi_k) = \frac{1}{N_{leaf}(\chi_k)} \sum_{c=1}^{N_{leaf}(\chi_k)} Idist_c, \quad (2.13)$$

де $Idist_c$ – середня відстань між екземплярами вибірки S , що попадають у c -й лист дерева χ_k , – величина, що розраховується за формулою (2.14):

$$Idist_c = \frac{1}{N_{inst}(Leaf_c)} \sum_{q=1}^{N_{inst}(Leaf_c)} \sqrt{\sum_{m=1}^M (p_{mq} - \overline{p_{mc}})^2}, \quad (2.14)$$

де $N_{inst}(Leaf_c)$ – кількість екземплярів вибірки S , що попадають у c -й лист $Leaf_c$ дерева χ_k ;

$\overline{p_{mc}}$ – середнє значення m -ї ознаки екземплярів, що попадають у c -й лист дерева χ_k . З метою приведення значень показника $Idist(\chi_k)$ до одного інтервалу при аналізі різних вибірок даних, у якості значення ознак p_{mq} рекомендується використовувати нормовані значення;

– узагальнення моделі дерева $GenerM(\chi_k)$ – відношення кількості всіх параметрів $N_{param}(\chi_k)$ моделі, що налаштовуються, на основі дерева розв'язків до розмірності вибірки S (2.15):

$$GenerM(\chi_k) = \frac{N_{param}(\chi_k)}{Q \cdot M}, \quad (2.15)$$

де $N_{param}(\chi_k)$ – кількість параметрів дерева χ_k , що налаштовуються, – визначається за формулою: $N_{param}(\chi_k) = 2N_{node}(\chi_k)$, оскільки кожен вузол d_{ab} характеризується двома параметрами p_{mab} і p_{TRab} .

Як критерій інтерпретовності $Int(\chi_k)$ можна використовувати один із запропонованих вище критеріїв ($N_{branch}(\chi_k)$, $N_{node}(\chi_k)$, $N_{level}(\chi_k)$, $Br(\chi_k)$, $Idist(\chi_k)$) або їхнє сполучення.

Після оцінювання якості синтезованих дерев розв'язків χ_k , $k = 1, 2, \dots, N_\chi$ виконується перевірка критеріїв зупинення стохастичного пошуку. Як такі критерії можуть бути використані: досягнення прийняттого значення цільової функції $G(\chi_k)$, перевищення максимальне припустимої кількості ітерацій N_{It} , відсутність істотних поліпшень значення цільової функції $G(\chi_k)$ протягом заданої кількості ітерацій.

При невиконанні критеріїв зупинення виконується оператор відбору рішень χ_k для формування нової множини рішень $R^{(i)} \rightarrow R^{(i+1)} = \{\chi_1^{(i+1)}, \chi_2^{(i+1)}, \dots, \chi_{N_\chi}^{(i+1)}\}$. Для цього з множини $R^{(i)}$ відбираються рішення $\chi_k^{(i)}$ з метою створення набору рішень $RP^{(i)}$, допущених до відтворення – рішень, на основі яких буде згенеровано новий набір $R^{(i+1)}$.

Для відбору рішень $\chi_k^{(i)}$ у множині $RP^{(i)}$ кожній структурі $\chi_k^{(i)}$ ставиться у відповідність інтервал $GI(\chi_k) \in [GI_{\min}(\chi_k); GI_{\max}(\chi_k)]$. Величини $GI_{\min}(\chi_k)$ та $GI_{\max}(\chi_k)$ обчислюються за формулами (2.16) та (2.17):

$$GI_{\min}(\chi_k) = GI_{\max}(\chi_{k-1}), \quad (2.16)$$

$$GI_{\max}(\chi_k) = GI_{\min}(\chi_k) + G_O(\chi_k), \quad (2.17)$$

де $GI_{\min}(\chi_k)$ і $GI_{\max}(\chi_k)$ – мінімальне та максимальне значення в інтервалі $GI(\chi_k)$, відповідно;

$GI_{\min}(\chi_1) = 0$ – мінімальне значення в інтервалі $GI(\chi_1)$ першого рішення χ_1 в популяції $R^{(i)}$;

$G_O(\chi_k)$ – відносне значення цільової функції $G(\chi_k)$ рішення χ_k в множині $R^{(i)}$, визначається за формулою (2.18):

$$G_O(\chi_k) = \frac{G'(\chi_k)}{\sum_{K=1}^{N_\chi} (G'(\chi_K))}, \quad (2.18)$$

де $G'(\chi_k) = \max_{K=1,2,\dots,N_\chi} \{G(\chi_K)\} - G(\chi_k)$.

Як видно з наведених вище формул, $GI_{\min}(\chi_0) = 0$ і $GI_{\max}(\chi_{N_\chi}) = 1$. Отже, кожному рішенню χ_k ставиться у відповідність деякий інтервал у залежності від значення його цільової функції $G(\chi_k)$: чим краще (менше) значення $G(\chi_k)$, тим більше значення $G'(\chi_k)$ та ширше інтервал $[GI_{\min}(\chi_k); GI_{\max}(\chi_k)]$. У сукупності інтервали $GI(\chi_k)$, $k = 1, 2, \dots, N_\chi$ утворюють інтервал $GI(R^{(i)}) \in [0; 1]$.

Після цього генерується випадкове число $rnd = rand[0; 1]$ з інтервалу $[0; 1]$. В множину допущених до відтворення рішень $RP^{(i)}$ заноситься рішення χ_k , в інтервал $GI(\chi_k)$ якого потрапляє випадково згенероване число rnd : $rnd \in [GI_{\min}(\chi_k); GI_{\max}(\chi_k)]$. Таким чином, чим більшою є ширина діапазону $GI(\chi_k)$, що визначається значенням цільової функції $G(\chi_k)$, тим вищою є імовірність рішення χ_k бути відібраним для відтворення. Генерація випадкових чисел rnd і відбір рішень χ_k для відтворення продовжується доти, поки не буде цілком сформована множина $RP^{(i)}$, $|RP^{(i)}| = N_\chi$.

Потім на основі рішень χ_k з множини $RP^{(i)}$ виконується створення нових рішень $\chi_k^{(i+1)}$. Для цього з множини $RP^{(i)}$ вибираються випадковим чином два рішення $\chi_{parent\ 1}$ і $\chi_{parent\ 2}$. Після чого в кожному з рішень-батьків вибираються вузли $d_{abparent\ 1}$ і $d_{abparent\ 2}$ (при цьому ознака-перевірка $p_{mabparent\ 2}$ вузла $d_{abparent\ 2}$ не повинна бути ідентичною кожній з ознак, що містяться у вузлах дерева $\chi_{parent\ 1}$ по напрямку від його кореня до вузла $d_{abparent\ 1}$, включно,

аналогічна умова діє і при виборі вузла $d_{abparent\ 1}$), по яких буде здійснюватися обмін між відповідними частинами дерев розв'язків $\chi_{parent\ 1}$ і $\chi_{parent\ 2}$. У результаті такого обміну утворюються два нових рішення $\chi_{child\ 1}$ і $\chi_{child\ 2}$. При цьому перше рішення-нащадок $\chi_{child\ 1}$ є ідентичним рішенню $\chi_{parent\ 1}$ за винятком частини (піддерева), вихідним вузлом якої є $d_{abparent\ 1}$. Замість вузла $d_{abparent\ 1}$ в рішенні $\chi_{child\ 1}$ знаходиться вузол $d_{abparent\ 2}$, після якого розташовується відповідна частина дерева $\chi_{parent\ 2}$. Аналогічно формується дерево-нащадок $\chi_{child\ 2}$. Після цього виконується перерахунок граничних значень p_{TRab} ознак-перевірок p_{mab} від вузла $d_{abparent\ 2}$ ($d_{abparent\ 1}$) дерева $\chi_{child\ 1}$ ($\chi_{child\ 2}$) до відповідних кінцевих вузлів, що містять значення вихідного параметра. У випадку, якщо в результаті таких перетворень на нижніх рівнях дерев $\chi_{child\ 1}$ і $\chi_{child\ 2}$ виявляються вузли, перевірки в яких пов'язані з ознаками, що вже зустрічаються на більш високих рівнях дерева при проході від кореня до відповідних листів, то такі ознаки-перевірки у вузлах низьких рівнів замінюються на ознаки-перевірки наступного рівня відповідного дерева $\chi_{child\ 1}$ або $\chi_{child\ 2}$. Такий підхід дозволяє для однакових батьків створювати множину нащадків. Створення нових рішень $\chi_k^{(i+1)}$ за допомогою описаного вище підходу продовжується доти, поки не буде сформовано $N_{cross} = \beta N_\chi$ рішень, де β – коефіцієнт, що визначає значущість формування нової множини рішень за допомогою описаної вище процедури схрещування.

Другим способом формування нових рішень $\chi_k^{(i+1)}$ є мутація, що передбачає виконання деяких змін над структурою χ_k , відібраною з множини $RP^{(i)}$. У розробленому стохастичному методі синтезу дерев розв'язків оператор

мутації пропонується виконувати в такий спосіб. Спочатку з множини $RP^{(i)}$ відбирається рішення $\chi_{mutated}$, у якому випадковим чином вибирається мутуючий вузол $d_{abmutated}$, потім у цьому вузлі виконується заміна ознаки-перевірки p_{mab} на іншу, що не міститься у вузлах дерева $\chi_{mutated}$ по напрямку від його кореня до вузла $d_{abmutated}$, включно. Після визначення нової ознаки-перевірки, виконується перерахунок її граничного значення p_{TRab} і подальше переформатування дерева, починаючи від вузла $d_{abmutated}$ (аналогічно етапу ініціалізації відбувається побудова фрагмента дерева від вузла $d_{abmutated}$ і доти, поки не будуть досягнуті відповідні критерії зупинення процесу формування дерева). Формування нових рішень $\chi_k^{(i+1)}$ за допомогою мутації продовжується, поки не буде сформовано $N_{mutation} = \gamma N_\chi$ рішень, де γ – коефіцієнт, що визначає значущість створення нової множини рішень за допомогою мутації.

У нову множину рішень $R^{(i+1)}$ заносяться N_{cross} і $N_{mutation}$ рішень, створених за допомогою схрещування і мутації, а також $N_{elite} = \alpha N_\chi$ елітних рішень $\chi_k^{(i)}$ з множини $R^{(i)}$, що характеризуються найкращими значеннями цільової функції $G(\chi_k^{(i)})$ в популяції $R^{(i)}$, де α – коефіцієнт, який визначає значущість включення елітних особин у нову множину.

Потім виконується оцінювання значень цільової функції G для рішень $\chi_k^{(i+1)}$: $G = G(\chi_k^{(i+1)})$, $k = 1, 2, \dots, N_\chi$ і формування нової множини $R^{(i+2)} = \{\chi_1^{(i+2)}, \chi_2^{(i+2)}, \dots, \chi_{N_\chi}^{(i+2)}\}$. Даний процес продовжується до виконання критеріїв зупинення.

Результатом виконання стохастичного методу синтезу дерев розв'язків є дерево χ_{opt} з мінімальним значенням цільової функції $G(\chi_{opt}) = \min_{k=1,2,\dots,N_\chi} \{G(\chi_k)\}$.

Після цього на основі синтезованого дерева розв'язків χ_{opt} виконується видобування правил RB , що являють собою найбільш цінні екземпляри. Для

цього обробляється кожен шлях від кореня дерева до листа χ_{opt} , у результаті чого будується відповідне правило, що узагальнює інформацію, подану в деякій множині екземплярів вихідної вибірки S . Використовуючи такий підхід, видобувається N_{RDT} правил, загальна кількість яких дорівнює кількості листів (кінцевих вузлів, що містять значення вихідного параметра) синтезованого дерева розв'язків χ_{opt} .

Оцінимо обчислювальну складність (часову та просторову) запропонованого стохастичного методу синтезу дерев розв'язків.

Як відзначено вище, на етапі ініціалізації обчислюється інформативність V_m кожної з N_χ ознак, обробляючи при цьому інформацію про кожен з екземплярів множини $S = \langle P, T \rangle$. Часова складність процесу оцінювання інформативності може бути оцінена як $O_{inf} = O(MQ)$.

Потім генерується N_χ дерев розв'язків. Для генерації кожного вузла кожного з N_χ дерев розв'язків виконується перебір всіх ознак p_m ($m = 1, 2, \dots, M$), отже, часова складність цього процесу складає $O_g = O(N_\chi M^2)$.

Найбільш ресурсномістким етапом стохастичного пошуку при синтезі дерев розв'язків є оцінювання розпізнавальних можливостей кожного дерева розв'язків, що вимагає обробки навчальної вибірки $S = \langle P, T \rangle$. При цьому важливо врахувати, що на кожній з N_{iter} ітерацій пошуку відбувається оцінювання N_χ дерев розв'язків. Часову складність цього етапу визначимо в такий спосіб: $O_s = O(N_\chi MQN_{iter})$.

Отже, загальна часова складність як кількість елементарних операцій, необхідних для розв'язання задачі за допомогою запропонованого методу, може бути визначена так: $O_{DT} = O_{inf} + O_g + O_s = O(MQ) + O(N_\chi M^2) + O(N_\chi MQN_{iter})$.

Враховуючи, що $N_\chi M^2 \ll N_\chi MQN_{iter}$ та $MQ \ll N_\chi MQN_{iter}$, остаточно одержуємо: $O_{DT} = O(N_\chi MQN_{iter})$.

Для визначення просторової складності запропонованого методу оцінимо кількість займаної пам'яті від розміру вхідних даних на кожному з етапів методу. Для функціонування методу необхідно зберігати інформацію про навчальну множину $S = \langle P, T \rangle$ та оцінки індивідуальних інформативностей ознак, на що буде потрібно $O(MQ + M)$ комірок пам'яті. Крім того, на кожній ітерації необхідно оперувати з кожним з N_χ дерев розв'язків, представленим у виді множини вузлів $d_{ab} = \langle p_{mab}, p_{TRab}, d_{(a+1)(2b-1)}, d_{(a+1)(2b)} \rangle$, новими рішеннями-нащадками, створеними за допомогою операторів схрещування і мутації, а також зі значеннями критеріїв оцінювання якості кожного з дерев розв'язків. Зазначені процедури вимагають використання $O(4MN_\chi + N_\chi + 4MN_\chi + N_\chi)$ комірок пам'яті.

Отже, просторова складність запропонованого методу може бути оцінена в такий спосіб: $O_{DTP} = O(MQ + M + 8MN_\chi + 2N_\chi)$.

Таким чином, розроблений стохастичний метод синтезу дерев розв'язків використовує інформацію про інформативність ознак, складність синтезованого дерева, а також точність його розпізнавання. Це дозволяє на початковому етапі формувати множину деревоподібних структур, які характеризуються простою ієрархією і невисокою помилкою розпізнавання, у процесі пошуку створювати нові множини рішень з урахуванням інформації про значущість ознак та інтерпретовність генерованих дерев, що, у свою чергу, забезпечує можливість побудови дерева розв'язків з невеликою кількістю елементів (вузлів і зв'язків між ними) і прийнятною точністю розпізнавання, а також відобування на його основі найбільш цінних екземплярів, що можуть використовуватися для побудови діагностичних моделей.

2.2 Побудова асоціативних правил на основі інтелектуального стохастичного пошуку

Для обробки наборів даних S , що містять велику кількість пропущених значень або поданих у вигляді баз транзакцій, де кожне спостереження (транзакція) містить значення деяких з можливих ознак P досліджуваних об'єктів, доцільно використовувати методи видобування асоціативних правил [133–141, 279, 280], оскільки вони дозволяють виявляти приховані залежності в даних, скорочувати розмірність даних, тим самим підвищуючи рівень узагальнення, а також знижуючи структурну та параметричну складність синтезованих на їхній основі моделей. У цьому випадку розглядається варіант вхідних даних, де деякі значення p_{qm} ознак або вихідного параметра t_q можуть бути не визначені. У результаті застосування методів виявлення асоціативних правил створюється множина $A = \{A_1, A_2, \dots, A_{N_A}\}$ правил виду $A_r : P_r \rightarrow T_r$, де P_r – антецедент – ліва частина r -го правила A_r , що визначає набір умов виконання правила A_r ; T_r – консеквент – права частина r -го правила A_r , що визначає значення вихідного параметра при виконанні умов P_r правила A_r ; $N_A = |A|$ – кількість видобутих правил [133–141].

Відомі методи видобування асоціативних правил SCF, SETM, Apriori, DHP, Eclat та інші [133–141] при формуванні наборів, що часто зустрічаються, у процесі синтезу правил використовують властивість антимонотонності підтримки (відповідно до якої підтримка набору елементів не перевищує значення підтримки кожної з його підмножин) чи інші процедури [133–141], що обумовлює наступні недоліки таких методів:

– такий підхід не дозволяє в процесі пошуку генерувати правила A_r з наборів ознак, що містять комбінації з низькими значеннями підтримки (комбінацій ознак, що рідко зустрічаються);

– аналогічно до жадібної стратегії пошуку аналізуються всі можливі комбінації з високими значеннями підтримки, що при великій кількості ознак P у вихідній множині S вимагає перевірки великої кількості комбінацій ознак P_r , виконуючи істотну кількість проходів по базі S і витрачаючи на це великі ресурси пам'яті і часу роботи ЕОМ;

– при використанні такого підходу виявляються тільки правила, складені на основі наборів, що часто зустрічаються, внаслідок чого не видобуваються цікаві правила $A_r : P_r \rightarrow T_r$ з високим рівнем вірогідності $\text{conf}(A_r)$ при низькому рівні підтримки $\text{supp}(A_r)$. Це істотно знижує апроксимаційні й узагальнювальні здібності синтезованої на основі виділеного набору $A = \{A_1, A_2, \dots, A_{N_A}\}$ асоціативних правил моделі якості виробів.

Крім того, більшість методів видобування асоціативних правил призначені для обробки бінарних даних. Проте більшість реальних задач неруйнівного контролю якості, діагностування та розпізнавання пов'язані з необхідністю обробки чисельних даних, де більшість ознак приймають значення з деякого діапазону.

Потреба в усуненні зазначених недоліків обумовлює необхідність розробки нового методу видобування асоціативних правил.

У цьому розділі роботи для видобування асоціативних правил $A_r : P_r \rightarrow T_r$ із заданих наборів чисельних даних S пропонується попередньо розбивати діапазони значень ознак P на інтервали, на основі яких визначати терми ознак, враховуючи при цьому ширину діапазону значень і частоту попадання ознак у кожний з термів, після чого за допомогою стохастичного підходу виявляти асоціативні правила $A_r : P_r \rightarrow T_r$, що характеризуються високим рівнем вірогідності $\text{conf}(A_r)$ [281].

У розробленому стохастичному методі видобування чисельних асоціативних правил на початковому етапі відбувається виділення термів ознак. Як терми можуть використовуватися можливі значення номінальних ознак або

інтервали значень числових ознак [282]. Розбиття діапазонів $p_m \in [p_{m \min}; p_{m \max}]$ значень числових ознак можна виконати шляхом рівномірного розбиття на певну кількість $N_{\text{int } m}$ інтервалів. Крім того, для цього в множині значень p_{qm} кожної ознаки p_m можна провести кластерний аналіз [57–63, 130–132], виділивши групи компактно розташованих екземплярів (транзакцій) в одновимірному просторі кожної ознаки. У результаті виділяється набір кластерів $Cl_m = \{Cl_{1m}, Cl_{2m}, \dots, Cl_{N_{\text{int } m}}\}$. При використанні методів кластерного аналізу, де потрібно задавати кількість кластерів N_{int} (наприклад, методу нечітких с-середніх [57–63, 97, 98, 115, 130–132]), як параметр $N_{\text{int } m}$ можна задати зменшену в N_A разів кількість екземплярів $N(p_m)$, для яких є визначеним значення ознаки p_m . Параметр N_A роботи методу може бути визначений за формулою (2.19):

$$N_A = \text{div} \left(\frac{1}{M \cdot N_{\text{int } mean}} \sum_{m=1}^M N(p_m) \right), \quad (2.19)$$

де $N_{\text{int } mean}$ – очікуване середнє значення інтервалів розбиття (кластерів) кожного з ознак p_m , $m = 1, 2, \dots, M$;

$\text{div}(x)$ – функція, що повертає цілу частину числа x .

Число $N_{\text{int } mean}$ повинно бути невеликим (наприклад, можна рекомендувати задавати $N_{\text{int } mean} = 10, N_{\text{int } mean} \ll Q$), що дозволить забезпечити невисокі вимоги до ресурсів пам'яті ЕОМ при виконанні відповідних обчислень, і в той же час таким, що дозволить забезпечити прийнятне розбиття значень ознак p_m на інтервали.

Потім на основі границь $Cl_{n \min m}$ і $Cl_{n \max m}$ ($n = 1, 2, \dots, N_{\text{int } m}$, $m = 1, 2, \dots, M$) виділених кластерів визначаються інтервали значень (терми) $[Cl_{n \min m}; Cl_{n \max m}]$ ознак p_m .

Після цього генерується N_χ рішень для виконання стохастичного пошуку. Рішення χ_k при видобуванні асоціативних правил подається у вигляді множини параметрів $\chi_k = \{g_{1k}, g_{2k}, \dots, g_{N_g k}\}$, де g_{mk} – m -й параметр рішення, що містить інформацію про номер терму Δp_{nm} m -ї ознаки p_m (або її відсутність) у k -му асоціативному правилі $A_k : P_k \rightarrow T_k$ (рис. 2.2).




Рисунок 2.2 – Подання структури χ_k при видобуванні асоціативних правил

Як видно, у рішенні χ_k також присутня інформація про терм ΔT_n вихідного параметру T (у випадку, якщо він приймає дійсні значення). Якщо вихідний параметр T не задано, то останній ген g_{N_g} рішення χ_k відсутній.

Значення m -го параметру g_m кожного k -го рішення χ_k визначаються в такий спосіб. Генерується випадкове число rnd з діапазону $[0;1]$ ($rnd = rand[0;1]$, де $rand[0;1]$ – функція, що повертає випадково згенероване число з інтервалу $[0;1]$). Якщо згенероване число rnd перевищує частоту v_m появи m -ї ознаки p_m у вибірці S ($rnd > v_m$), то значенню параметра g_m рішення χ_k присвоюється нульове значення ($g_{mk} = 0$), що характеризує відсутність m -ї ознаки в k -му асоціативному правилі χ_k . Величина v_m обчислюється за формулою (2.20):

$$v_m = \frac{N(p_m)}{Q}, \quad (2.20)$$

де $N(p_m)$ – кількість екземплярів вибірки S , у яких визначеними є значення m -ї ознаки.

У випадку, якщо $rnd \leq v_m$, значення параметра g_m відповідає номеру інтервалу Δv_{nm} , у який потрапило випадкове число rnd : $g_m = n$, $rnd \in \Delta v_{nm}$. При цьому ширина інтервалу Δv_{nm} характеризує частоту появи n -го терму Δp_{nm} m -ї ознаки p_m в транзакціях вибірки S (2.21):

$$\Delta v_{nm} \in (\Delta v_{n-1m_{\max}}; \Delta v_{n-1m_{\max}} + v_{nm} v_m] . \quad (2.21)$$

При цьому інтервал Δv_{1m} першого терму Δp_{1m} m -ї ознаки визначається таким чином: $\Delta v_{1m} \in [0; v_{1m} v_m]$. Величина v_{nm} визначається за формулою (2.22):

$$v_{nm} = \frac{N(p_{nm})}{N(p_m)}, \quad (2.22)$$

де $N(p_{nm})$ – кількість екземплярів вибірки S , значення m -х ознак яких попадає в n -й терм Δp_{nm} .

Таким чином n -й терм Δp_{nm} m -ї ознаки p_m має тим більшу імовірність увійти до k -го правила χ_k , чим вищою є частота v_{nm} його наявності в транзакціях вибірки S , у яких визначеними є значення m -ї ознаки.

При числовому значенні вихідного параметра T величина v_{nm} для k -го рішення χ_k обчислюється як частота наявності терму Δp_{nm} в транзакціях вибірки S , у яких визначені значення m -ї ознаки, а значення вихідного параметра T дорівнює $g_{M+1,k}$.

Аналогічним чином формуються M параметрів g_m для кожного з N_χ рішень початкової популяції $R^{(0)} = \{\chi_1^{(0)}, \chi_2^{(0)}, \dots, \chi_{N_\chi}^{(0)}\}$ стохастичного пошуку, що являє собою множину асоціативних правил.

У випадку числового вихідного параметра T вибірки S значення гена $g_{M+1,k}$, що визначає номер терму вихідного параметра в правилі χ_k , генерується випадковим чином у залежності від частоти появи термів у вибірці S . Для цього по формулі (2.23) визначається імовірність того, що значення вихідного параметра T екземплярів вибірки S потрапить до n -го інтервал T_n діапазону його зміни:

$$\rho(T_n) = \frac{N(T_n)}{Q}, \quad (2.23)$$

після чого кожному терму T_n ставиться у відповідність інтервал (2.24):

$$\rho i(T_n) \in (T_{n-1, \max}; T_{n-1, \max} + \rho(T_n)], \quad (2.24)$$

при цьому $\rho i(T_1) \in [0; \rho(T_1)]$. Далі генерується випадкове число $rnd = rand[0;1]$. Значення параметра $g_{M+1,k}$ відповідає номеру інтервалу $\rho i(T_n)$, у який потрапило випадкове число rnd : $g_{M+1,k} = n, rnd \in \rho i(T_n)$.

Потім обчислюється вірогідність $\text{conf}(\chi_k)$ кожного рішення. Для цього рішення χ_k перетворюються в асоціативні правила: $\chi_k \rightarrow A_k$. При цьому асоціативне правило A_k формується з ненульових параметрів g_{mk} рішення χ_k , у результаті чого виходить імплікація вигляду (2.25):

$$\bigcap (p_m \in p_{nm}) \rightarrow T. \quad (2.25)$$

При дійсних значеннях вихідного параметра T консеквент імплікації (2.25) може бути представлений у вигляді: $T \in \Delta T(g_{M+1,k})$, де $\Delta T(g_{M+1,k})$ – терм T_n вихідного параметра T , що визначається номером, поданим в останньому гені $g_{M+1,k}$ рішення χ_k .

Після виконання перетворень вигляду $\chi_k \rightarrow A_k$ обчислюються вірогідності $\text{conf}(A_k)$ правил A_k (2.26):

$$\text{conf}(A_k) = \frac{\text{supp}(P_k \cup T_k)}{\text{supp}(P_k)}, \quad (2.26)$$

де $\text{supp}(P_k \cup T_k)$ – підтримка правила $A_k : P_k \rightarrow T_k$, що розраховується як відношення кількості екземплярів $N(P_k \cup T_k)$ вибірки S , що містять множину умов P_k і характеризуються значенням вихідного параметра T_k , до кількості екземплярів вибірки S , що задовольняють умовам антецедента P_k правила $A_k : P_k \rightarrow T_k$.

Потім у поточну множину рішень A вводяться достовірні асоціативні правила A_k (правила з рівнем вірогідності $\text{conf}(A_k)$, не нижче заданого minconf : $\text{conf}(A_k) \geq \text{minconf}$). Крім критерію вірогідності (2.26) для більш детального дослідження асоціативних правил, що видобуваються, при стохастичному пошуку також пропонується враховувати інші критерії, які характеризують частоту виконання правил, їхню інформативність та інтерпретовність (зручність для сприйняття людиною):

– підтримка правила $\text{supp}(A_k)$ [133–141] – дозволяє оцінити частоту виконання правила у вибірці S і може бути визначена за формулою (2.27) або (2.28):

$$\text{supp}(A_k) = \text{supp}(P_k \cup T_k) = N(P_k \cup T_k), \quad (2.27)$$

$$\text{supp}(A_k) = \text{supp}(P_k \cup T_k) = \frac{N(P_k \cup T_k)}{Q}, \quad (2.28)$$

при цьому формула (2.27) дозволяє визначити абсолютну величину підтримки як кількість екземплярів вибірки S , для яких виконується правило $A_k : P_k \rightarrow T_k$, а формула (2.28) призначена для визначення відносної величини підтримки як відношення $N(P_k \cup T_k)$ до загальної кількості екземплярів Q у вибірці S ;

– загальна підтримка правила $\text{suppG}(A_k)$ – враховує не тільки частоту виконання позитивних умов правил вигляду $P_k \rightarrow T_k$, але і негативних умов $\overline{P_k} \rightarrow \overline{T_k}$, визначається за формулою (2.29):

$$\text{suppG}(A_k) = \text{supp}(P_k \cup T_k) + \text{supp}(\overline{P_k} \cup \overline{T_k}), \quad (2.29)$$

чим вищим є значення даного критерію, тим більш значущим є правило $A_k : P_k \rightarrow T_k$ у вибірці S , оскільки велика кількість випадків одночасного виконання (одночасного невиконання) умов антецедента P_k і консеквента T_k свідчить про істотний зв'язок між P_k і T_k ;

– загальна вірогідність правила $\text{confG}(A_k)$ – аналогічно критерію $\text{suppG}(A_k)$ враховує частоту виконання як позитивних так і негативних умов правил $A_k : P_k \rightarrow T_k$, визначається за формулою (2.30):

$$\begin{aligned} \text{confG}(A_k) &= \frac{1}{2} (\text{conf}(P_k \rightarrow T_k) + \text{conf}(\overline{P_k} \rightarrow \overline{T_k})) = \\ &= \frac{1}{2} \left(\frac{\text{supp}(P_k \cup T_k)}{\text{supp}(P_k)} + \frac{\text{supp}(\overline{P_k} \cup \overline{T_k})}{\text{supp}(\overline{P_k})} \right); \end{aligned} \quad (2.30)$$

– складність правила $VS(A_k)$ – визначається, виходячи з відношення кількості ознак (умов) $N(P_k)$, визначених у лівій частині (антецеденті) правила $A_k : P_k \rightarrow T_k$, до загальної кількості ознак M у вибірці S (2.31):

$$VS(A_k) = 1 - \frac{N(P_k)}{M}, \quad (2.31)$$

чим вище значення даного критерію, тим правило $A_k : P_k \rightarrow T_k$ є більш простим (інтерпретовним) і охоплює більш широкий спектр випадків, тим самим забезпечуючи високе узагальнення даних. Чим більше умов $N(P_k)$ в антецеденті правила (відповідно, чим менше значення критерію $VS(A_k)$), тим воно є більш специфічним;

– показник максимуму вірогідності правила $\text{confG}(A_k)$ й індивідуальних оцінок інформативності ознак $VC(A_k)$ (2.32):

$$VC(A_k) = \text{confG}(A_k) \sum_{m: p_m \in P_k} V_m, \quad (2.32)$$

де V_m – оцінка індивідуальної значущості m -ї ознаки p_m , що входить в антецедент P_k правила $A_k : P_k \rightarrow T_k$. Відзначимо, що поряд з оцінкою $\text{confG}(A_k)$ у формулі (2.32) можна використовувати також значення вірогідності $\text{conf}(A_k)$;

– показник максимуму вірогідності правила $\text{confG}(A_k)$ – мінімуму кількості $N(P_k)$ відібраних ознак $VM(A_k)$ (2.33):

$$VM(A_k) = \frac{1}{N(P_k)} \text{confG}(A_k); \quad (2.33)$$

– інформативність правила $VI(A_k)$ – критерій, що дозволяє враховувати як вірогідність (значущість) усього правила $A_k : P_k \rightarrow T_k$, так і індивідуальну інформативність V_m кожної ознаки p_m , що входить у його антецедент P_k . Критерій $VI(A_k)$ пропонується розраховувати за формулою (2.34):

$$VI(A_k) = \frac{1}{N(P_k)} \text{confG}(A_k) \sum_{m: p_m \in P_k} V_m. \quad (2.34)$$

Критерій (2.34) забезпечує пошук правил $A_k : P_k \rightarrow T_k$ з максимальною вірогідністю $\text{confG}(A_k)$, максимальними оцінками індивідуальних інформативностей V_m ознак і мінімальною кількістю $N(P_k)$ ознак p_m , що входять в антецедент P_k правила.

Оцінку індивідуальної інформативності V_m m -ї ознаки p_m можна визначити як суму індивідуальних інформативностей V_{nm} термів цієї ознаки (2.35):

$$V_m = \sum_{n=1}^{N_{\text{int}m}} V_{nm}, \quad (2.35)$$

де V_{nm} – оцінка інформативності n -го терму Δp_{nm} m -ї ознаки p_m , може бути розрахована за формулою (2.36):

$$V_{nm} = 1 + \sum_{l=1}^{N_{\text{int}T}} \rho(\Delta p_{nm}, T_l) \log \rho(\Delta p_{nm}, T_l), \quad (2.36)$$

де $\rho(\Delta p_{nm}, T_l) = \frac{N(p_{nm}, T_l)}{N(p_{nm})}$ – умовна імовірність того, що значення вихідного

параметра T потрапить у l -й інтервал T_l за умови, що m -а ознака p_m потрапить у n -й терм Δp_{nm} ;

$N(p_{nm}, T_l)$ – кількість екземплярів вибірки S , значення вихідного параметра T яких належать l -му інтервалу діапазону його зміни T_l за умови, що значення їх m -ї ознаки належить n -му інтервалу p_{nm} ;

$N_{\text{int}}(T)$ – кількість інтервалів, на які розбивається діапазон значень вихідного параметра T .

Запропонована система критеріїв (2.26)–(2.34) дозволяє враховувати різні характеристики асоціативних правил, що характеризують їхню

вірогідність, частоту виконання, інформативність та інтерпретовність, може бути використана для автоматизації аналізу властивостей і порівняння моделей на основі асоціативних правил при вирішенні задач діагностування, розпізнавання образів і неруйнівного контролю якості.

Важливо відзначити, що при виборі правил $A_k : P_k \rightarrow T_k$ для внесення в множину $A = \{A_1, A_2, \dots, A_{N_A}\}$, яка являє собою базу синтезованих асоціативних правил, можливо використовувати як один заданий критерій (наприклад, інформативність правила $VI(A_k)$) так і сполучення декількох критеріїв із запропонованої системи (2.26)–(2.34). Крім того, також можливо обчислювати оцінки даних критеріїв і на тестовій вибірці, що дозволить враховувати узагальнювальні характеристики правил, що видобуваються.

Після обчислення оцінок якості видобутих асоціативних правил χ_k ($A_k : P_k \rightarrow T_k$), $k = 1, 2, \dots, N_\chi$ і внесення кращих з них у множину $A = \{A_1, A_2, \dots, A_{N_A}\}$ відбувається перевірка критеріїв завершення стохастичного пошуку: досягнення максимально припустимої кількості правил у множині A ($N_A \geq N_{A_{\max}}$), перевищення максимально припустимої кількості ітерацій N_{It} , неможливість протягом заданої кількості ітерацій видобування правил $A_k : P_k \rightarrow T_k$, що володіють прийнятними значеннями критеріїв їхнього оцінювання.

У випадку невиконання критеріїв завершення стохастичного пошуку відбувається формування нових N_χ рішень χ_k . Для цього створюється множина $RP^{(i)}$ рішень χ_k , допущених до формування нової множини рішень $R^{(i+1)}$. В множину $RP^{(i)}$ заносяться найбільш пристосовані структури χ_k (у залежності від значень критеріїв оцінювання асоціативних правил A_k) з множини рішень $R^{(i)} = \{\chi_1^{(i)}, \chi_2^{(i)}, \dots, \chi_{N_\chi}^{(i)}\}$ i -ї ітерації стохастичного пошуку.

Потім на основі рішень $\chi_{parent1} = \{g_{1parent1}, g_{2parent1}, \dots, g_{N_g parent1}\} \in RP^{(i)}$ та $\chi_{parent2} = \{g_{1parent2}, g_{2parent2}, \dots, g_{N_g parent2}\} \in RP^{(i)}$ створюється нове рішення χ_{child} . Значення параметрів g_{mchild} нащадка χ_{child} визначаються за формулою (2.37):

$$g_{mchild1} = \begin{cases} g_{mparent1}, rnd \in \left[0; \frac{V_{mparent1}}{V_{mparent1} + V_{mparent2}} \right); \\ g_{mparent2}, rnd \in \left[\frac{V_{mparent1}}{V_{mparent1} + V_{mparent2}}; 1 \right], \end{cases} \quad (2.37)$$

де $V_{mparent1}$ і $V_{mparent2}$ – інформативність $g_{mparent1}$ -го та $g_{mparent2}$ -го термів m -ї ознаки, відповідно;

$$rnd = rand[0;1].$$

Наведена формула (2.37) дозволяє підсилювати ймовірність включення в нове рішення χ_{child} параметрів g_{mk} , що відповідають термам Δp_{nm} ознак з високими оцінками індивідуальної інформативності V_{nm} .

Таким чином, відбувається формування $N_{cross} = \beta N_\chi$ рішень виду $\chi_k^{(i+1)} = \{g_{1k}^{(i+1)}, g_{2k}^{(i+1)}, \dots, g_{N_g k}^{(i+1)}\}$, де β – параметр, що визначає значущість створення нової множини рішень $R^{(i+1)}$ за допомогою запропонованої вище процедури схрещування.

Потім створюється $N_{mutation} = \gamma N_\chi$ рішень за допомогою оператора мутації, де γ – параметр, що визначає значущість формування нової множини рішень $R^{(i+1)}$ за допомогою процедури мутації. Для цього з множини $RP^{(i)}$ випадковим чином вибирається рішення χ_{parent} , у якому значення деяких параметрів $g_{mparent}$, що визначають номер терму Δp_{nm} m -ї ознаки p_m у відповідному асоціативному правилі, змінюються, у результаті чого створюється нове рішення χ_{child} . Нові значення змінюваних параметрів g_{mchild}

визначаються стохастичним шляхом з урахуванням оцінок індивідуальних значущостей V_{nm} термів Δp_{nm} відповідної ознаки.

Кожному терму Δp_{nm} ($n=1,2,\dots,N_{\text{int } m}$) m -ї ознаки p_m ставиться у відповідність інтервал (2.38)

$$gI(\Delta p_{nm}) \in [gI_{\min}(\Delta p_{nm}); gI_{\max}(\Delta p_{nm})], \quad (2.38)$$

де $gI_{\min}(\Delta p_{nm}) = gI_{\max}(\Delta p_{n-1,m})$ – мінімальне значення інтервалу $gI(\Delta p_{nm})$;

$gI_{\max}(\Delta p_{nm}) = gI_{\min}(\Delta p_{nm}) + VN_{nm}$ – максимальне значення інтервалу $gI(\Delta p_{nm})$;

VN_{nm} – приведені значення оцінки індивідуальної значущості V_{nm} терму Δp_{nm} , розраховані за формулою (2.39):

$$VN_{nm} = \frac{V_{nm}}{\sum_{k=1}^{N_{\text{int } m}} V_{km}}; \quad (2.39)$$

$gI_{\min}(\Delta p_{1m}) = 0$ – мінімальне значення в інтервалі $gI(\Delta p_{1m})$ першого терму Δp_{1m} ознаки p_m .

Таким чином, чим вищим буде значення величини V_{nm} (VN_{nm}), тим ширшим буде діапазон значень $gI(\Delta p_{nm})$ терму Δp_{nm} .

Після обчислення границь інтервалів $gI(\Delta p_{nm})$ ($n=1,2,\dots,N_{\text{int } m}$, $m=1,2,\dots,M$) генерується випадкове число $rnd = rand[0;1)$. Нові значення параметрів g_{mchild} рішення χ_{parent} , обраного для мутації, відповідають номеру n інтервалу $gI(\Delta p_{nm})$, у який потрапляє число rnd (2.40):

$$g_{mchild} = n, rnd \in gI(\Delta p_{nm}). \quad (2.40)$$

Отже, чим ширшим є діапазон $gI(\Delta p_{nm})$, тим більшою є ймовірність терму Δp_{nm} бути включеним у рішення χ_{child} .

У нову множину $R^{(i+1)}$ крім $N_{cross} = \beta N_\chi$ і $N_{mutation} = \gamma N_\chi$ рішень, отриманих за допомогою процедур схрещування і мутації, заноситься також $N_{elite} = \alpha N_\chi$ найбільш пристосованих рішень $\chi_k^{(i)} \in R^{(i)}$, що характеризуються найкращими значеннями критеріїв оцінювання асоціативних правил A_k у популяції $R^{(i)}$, де α – параметр, що визначає значущість включення найкращих рішень у нову множину $R^{(i+1)}$.

Потім виконується обчислення вірогідності $\text{conf}(\chi_k)$ й інших критеріїв оцінювання рішень χ_k з нової популяції $R^{(i+1)}$ з наступним внесенням кращих з рішень χ_k у множину $A = \{A_1, A_2, \dots, A_{N_A}\}$, і при невиконанні критеріїв зупинення стохастичного пошуку відбувається створення нової множини рішень $R^{(i+2)}$.

У результаті стохастичного пошуку видобувається набір $A = \{A_1, A_2, \dots, A_{N_A}\}$ асоціативних правил виду $A_k : P_k \rightarrow T_k$, що характеризуються прийнятними значеннями заданих критеріїв оцінювання якості правил.

Часова обчислювальна складність O_{AR} запропонованого стохастичного методу видобування чисельних асоціативних правил може бути оцінена як сума величин, що визначають часову складність його основних найбільш ресурсномістких етапів: $O_{AR} = O_{\text{int}} + O_g + O_s$.

У розробленому методі на початковому етапі відбувається розбиття значень ознак P на інтервали. Даний процес пов'язаний з необхідністю обробки кожного значення p_{qm} кожної ознаки p_m ($m = 1, 2, \dots, M$, $q = 1, 2, \dots, Q$). Тому часова складність розбиття значень ознак множини $S = \langle P, T \rangle$ на інтервали може бути оцінена як $O_{\text{int}} = O(MQ)$.

На створення N_χ рішень у вигляді лінійних структур даних, кожна комірка яких g_{mk} ($m = 1, 2, \dots, M + 1$) містить інформацію про номер терму Δp_{nm} m -ї ознаки p_m , може бути витрачено $O_g = O(N_\chi M)$ елементарних операцій.

Етап перетворення $\chi_k \rightarrow A_k$ структур χ_k в асоціативні правила A_k ($k = 1, 2, \dots, N_\chi$) і їхнього наступного оцінювання пов'язаний з необхідністю обробки вибірки $S = \langle P, T \rangle$. Отже, часова складність цього етапу може бути оцінена як $O_s = O(N_\chi M Q N_{iter})$, N_{iter} – кількість ітерацій стохастичного пошуку при видобуванні асоціативних правил. Етапи створення нових рішень за допомогою операторів схрещування і мутації вимагають істотно меншої кількості елементарних операцій, оскільки не передбачають необхідності обробки вибірки $S = \langle P, T \rangle$.

Таким чином, часову складність O_{AR} запропонованого стохастичного методу видобування чисельних асоціативних правил можна оцінити за формулою: $O_{AR} = O_{int} + O_g + O_s = O(MQ) + O(N_\chi M) + O(N_\chi M Q N_{iter}) = O(N_\chi M Q N_{iter})$.

Просторову складність O_{ARp} запропонованого методу визначимо в такий спосіб. На збереження інформації про навчальну вибірку $S = \langle P, T \rangle$ та діапазони значень ознак p_m буде потрібно $O(MQ + MQ)$ комірок пам'яті. Також необхідно зберігати інформацію про поточну множину рішень $\chi_k = \{g_{1k}, g_{2k}, \dots, g_{N_g k}\}$ ($N_g = M + 1, k = 1, 2, \dots, N_\chi$) і множину рішень-нащадків, створених за допомогою еволюційних операторів схрещування і мутації. Крім цього для кожного рішення обчислюється значення його критерію оцінювання. Тому для можливості виконання зазначених етапів необхідно $O((M + 1)N_\chi + N_\chi + (M + 1)N_\chi + N_\chi) = O(2MN_\chi + 4N_\chi)$ комірок пам'яті. Виходячи з вищесказаного, просторову складність розробленого методу оцінимо за формулою: $O_{ARp} = O(MQ + MQ) + O(2MN_\chi + 4N_\chi) = O(2MQ + 2MN_\chi + 4N_\chi)$.

Запропонований стохастичний метод видобування чисельних асоціативних правил передбачає попереднє розбиття значень ознак на інтервали (терми), враховуючи при цьому ширину діапазону значень і частоту потрапляння ознак у кожний з термів, використовує ймовірнісний підхід для перебору різних сполучень антецедентів і консеквентів асоціативних правил, використовує апіорну інформацію про значущість термів і ознак. Це дозволяє обробляти чисельну інформацію при видобуванні асоціативних правил, не здійснювати істотну кількість проходів по заданій базі транзакцій, виявляти правила з високим рівнем вірогідності й інших критеріїв оцінювання їхньої якості.

2.3 Видобування продукційних правил на основі негативного відбору для випадку нерівномірного розподілу екземплярів класів вибірки

У процесі побудови моделей прийняття рішень для неруїнівного контролю якості, технічного та медичного діагностування, розпізнавання образів можуть виникати ситуації, коли велика частина інформації в навчальній вибірці даних відноситься до одного класу (наприклад, переважна більшість виробів відноситься до одного класу придатності) [126–137, 164–168, 188–194].

У таких випадках для формалізації описів досліджуваних об'єктів або процесів доцільно синтезувати моделі на основі штучних імунних систем [164–187], що характеризуються можливостями навчання на основі екземплярів тільки одного класу, а також високим рівнем адаптації.

Для розв'язання задач, що характеризуються суттєвою різницею між кількістю екземплярів, які відносяться до різних класів, пропонується використовувати штучні імунні системи. Моделі на основі штучних імунних систем працюють на основі принципів негативного відбору [174–186], що

передбачає побудову набору детекторів (обчислювальних елементів), здатних до розпізнавання невідомих екземплярів [174–186]. Такий підхід дозволяє виявляти аномалії або випадкові зміни в діагностованих об'єктах [164–187], а також розпізнавати екземпляри чужих класів (класів об'єктів, екземпляри яких не представлені в навчальній вибірці) [164–187].

Однак відомі методи синтезу штучних імунних систем на основі негативного відбору [174–186] генерують надлишкову кількість детекторів (можливих рішень задачі), висувають значні вимоги до обчислювальних ресурсів ЕОМ, як правило, використовують інформацію тільки про один клас екземплярів («своїх», придатних і т.п.), не враховуючи при цьому дані про екземпляри інших класів. Отже, актуальною є розробка методів синтезу штучних імунних систем на основі негативного відбору, вільних від зазначених недоліків. Крім того, діагностичні моделі на основі штучних імунних систем характеризуються низьким рівнем узагальнення. Не дивлячись на те, що детектори (правила) імунної системи по окремоті є легкими в сприйнятті і розумінні людиною, через низький рівень узагальнення, система детекторів має велику розмірність, і, отже, є складною для сприйняття й аналізу людиною, що в цілому приводить до зниження інтерпретовності діагностичної моделі на основі імунних систем.

Тому в цьому підрозділі роботі пропонується виконувати синтез правил у вигляді набору продукцій $P_r \rightarrow T_r$ (P_r – набір умов виконання r -го правила; T_r – значення вихідного параметра при виконанні r -го набору умов P_r) на основі множини детекторів, виявлених при побудові штучної імунної системи на основі негативного відбору [174–186].

Метою підрозділу є створення методу синтезу продукційних правил на основі множини детекторів, що полягає в обробці даних навчальної вибірки, яка характеризується суттєвою різницею кількості екземплярів різних класів, та побудові моделі на основі штучної імунної системи шляхом застосування негативного відбору [283].

Нехай задана навчальна множина $S = \langle P, T \rangle$, де P – набір вхідних характеристик (ознак) об'єктів; T – множина значень вихідного параметра. Набір P подається у виді матриці $P = (p_{qm})_{QM}$, де p_{qm} – значення m -ї ознаки q -го екземпляра вибірки S ; $m = 1, 2, \dots, M$ – номер ознаки (характеристики) об'єкта; $q = 1, 2, \dots, Q$ – номер екземпляра (об'єкта) у вибірці S ; M – кількість ознак вибірки S ; Q – кількість екземплярів вибірки S . Набір значень вихідного параметра подається у вигляді вектора $T = (t_q)_Q$, де $t_q \in T'$ – значення вихідного параметра q -го екземпляра; T' – множина можливих значень вихідного параметра (як правило, у задачах неруйнівного контролю якості і розпізнавання образів множина T' складається з двох елементів $T' = \{t'_0, t'_1\}$, що визначають клас придатності виробу, наприклад при $t_q = t'_0$ q -й виріб вважається придатним, при $t_q = t'_1$ – некондиційним).

При цьому кількість екземплярів вибірки $S = \langle P, T \rangle$ одного класу (наприклад, екземплярів класу некондиційних $t_q = t'_1$) істотно відрізняється від кількості екземплярів іншого класу, що визначається нерівністю (2.41):

$$0 \leq N_{t_q=t'_0} \ll N_{t_q=t'_1}, \quad (2.41)$$

де $N_{t_q=t'_0}$ та $N_{t_q=t'_1}$ – кількість екземплярів вибірки $S = \langle P, T \rangle$, значення вихідного параметра t_q яких дорівнює t'_0 і t'_1 , відповідно, $N_{t_q=t'_0} + N_{t_q=t'_1} = Q$.

Тоді на основі заданої вибірки $S = \langle P, T \rangle$ необхідно синтезувати набір $RB = \{rule_1, rule_2, \dots, rule_{NR}\}$ продукцій $P_r \rightarrow T_r$, що дозволяє забезпечити прийнятний рівень помилки розпізнавання E , розрахованої як відношення кількості N_{er} неправильно розпізнаних за допомогою набору правил RB спостережень вибірки S до загальної кількості екземплярів Q .

Як відзначено вище, відомі методи негативного відбору [174–186] мають такі недоліки, як генерація надлишкової кількості детекторів, використання інформації про екземпляри тільки одного класу, низька інтерпретовність синтезованого набору рішень у вигляді детекторів. Крім того, більшість методів, заснованих на принципі негативного відбору, в якості детекторів використовують гіперсфери з фіксованим радіусом, який визначає область простору ознак, що покривається детектором. Вибір величини радіуса гіперсфери-детектору є собою дуже складною задачею, оскільки при великих значеннях радіуса знижується точність розпізнавання, а при низьких значеннях збільшується кількість генерованих детекторів, що у свою чергу знижує узагальнювальні властивості синтезованої моделі у вигляді набору детекторів штучної імунної мережі.

Наявність зазначених недоліків обумовлює необхідність висування суттєвих вимог до обчислювальних ресурсів ЕОМ при використанні відомих методів негативного відбору, що, у свою чергу, знижує швидкість пошуку рішення і, у деяких випадках, не дозволяє знайти прийнятне рішення.

Для усунення зазначених недоліків доцільно використовувати метод синтезу продукційних правил на основі негативного відбору для випадку нерівномірного розподілу екземплярів класів вибірки, у якому пропонується [284]:

– при генерації набору детекторів $AB = \{Ab_1, Ab_2, \dots, Ab_{N_{Ab}}\}$ використовувати відому інформацію про екземпляри обох класів $T' = \{t'_0, t'_1\}$, що дозволить сформувати набір детекторів з високими апроксимаційними й узагальнювальними властивостями;

– використовувати інформацію про індивідуальну значущість V_m ознак p_m , що дозволить виключити малозначущі та надлишкові ознаки з вибірки $S = \langle P, T \rangle$;

– як форму детектора використовувати гіперкуб максимально можливого обсягу. На відміну від відомих методів негативного відбору, у яких

в якості форми детектора використовується гіперсфера, це дозволить виключити необхідність розв'язання ресурсномісткої задачі пошуку оптимальних радіусів гіперсфер детекторів.

У розробленому методі на початковому етапі пропонується оцінювати значущість ознак p_m по відношенню до вихідного параметра T , що дозволить виявити та виключити з подальшого розгляду малозначущі ознаки, скоротивши тим самим простір пошуку та час виконання методу. Як відзначено вище, у цьому підрозділі розглядається задача, у якій вихідна вибірка $S = \langle P, T \rangle$ характеризується дискретною кількістю класів $T' = \{t'_0, t'_1\}$. Тому для оцінювання значущості V_m ознак p_m доцільно застосовувати критерії, що дозволяють виконувати оцінку інформативності ознак по відношенню до дискретного вихідного параметра T . В якості такого критерію пропонується використовувати ентропію ознаки $V_m = VE(p_m)$ як характеристику, що відображає ступінь невизначеності стану об'єкта й обчислюється за формулою (2.2).

Ознаки p_m , значення індивідуальної інформативності яких є нижчим мінімально припустимого ($V_m < V_{\min}$), вважаються малоінформативними і виключаються з вибірки $S = \langle P, T \rangle$.

Крім того, пропонується оцінити взаємозв'язок ознак як інформативність однієї з них відносно іншої, що дозволить виявити групи взаємозалежних ознак, у кожній з яких залишити тільки одну високо інформативну ознаку, а інші ознаки, пов'язані з нею у групі, можна виключити з подальшого розгляду, оскільки такі ознаки є надлишковими, ускладнюють процес синтезу діагностичних моделей і знижують їх інтерпретовність [285]. Для оцінювання інформативності ознак між собою V_{md} пропонується також застосовувати ентропію ознак, використовуючи формулу (2.2) і вважаючи при цьому одну з ознак p_d вихідним параметром T (попередньо інтервал значень

ознаки, що вважається вихідним параметром p_d , розбивається на $N_{\text{int}}(T)$ дискретних інтервалів).

Після оцінювання інформативності ознак по відношенню до інших ознак з вибірки S виключаються ті з них, для яких існують аналоги (у випадку, якщо значення взаємної інформативності ознак є більше максимально припустимого значення $V_{md} > V_{\text{max}}$).

Далі виконується побудова множини детекторів – структур, що дозволяють визначити, чи відноситься оцінюваний екземпляр до визначеного класу. Варто відзначити, що при використанні принципів негативного відбору детектори, які будуються на основі класу $T' = t'_1$, дозволяють виявити з невідомих екземплярів такі, що не відносяться до відповідного класу t'_1 [174–186]. Тому для формування множини детекторів у задачі розпізнавання, у якій вихідний параметр приймає два значення t'_1 (клас «своїх») і t'_0 (клас «чужих»), необхідно з вхідної вибірки $S = \langle P, T \rangle$ сформувати вибірки S_1 і S_0 з екземплярів, що відносяться до класів t'_1 і t'_0 , відповідно: $S_1 = \langle P, T = t'_1 \rangle$ (вибірка «своїх» екземплярів) і $S_0 = \langle P, T = t'_0 \rangle$ (вибірка «чужих» екземплярів).

Після цього виконується формування першого кандидата в детектори (2.42), поданого у виді гіперкуба:

$$Ab_1 = \langle Ab_{1\text{min}}, Ab_{1\text{max}} \rangle \in AB_1, \quad (2.42)$$

де $Ab_{1\text{min}} = \{Ab_{11\text{min}}, Ab_{12\text{min}}, \dots, Ab_{1M\text{min}}\}$ і $Ab_{1\text{max}} = \{Ab_{11\text{max}}, Ab_{12\text{max}}, \dots, Ab_{1M\text{max}}\}$ – відповідно, набори мінімальних і максимальних значень m -х ознак кандидата в детектори Ab_1 ;

$$Ab_{1m\text{min}} = \min_{q=1,2,\dots,Q_1} (p_{qm}), \quad m = 1, 2, \dots, M;$$

$$Ab_{1m\text{max}} = \max_{q=1,2,\dots,Q_1} (p_{qm}), \quad m = 1, 2, \dots, M;$$

Q_1 – кількість екземплярів у вибірці S_1 .

Множина AB_1 детекторів Ab_k формується на основі набору «своїх» екземплярів S_1 і дозволяє виявляти серед невідомих екземплярів «чужі», тобто такі, які не відносяться до класу t'_1 .

Потім для кожного q -го екземпляра s_q вибірки $S_1 = \langle P, T = t_1 \rangle$ визначається його відповідність кандидату в детектори Ab_k за формулою (2.43):

$$eq(Ab_k, s_q) = \begin{cases} 1, & \left(\sum_{m=1}^M \{1 | (Ab_{km \min} < p_{qm}) \wedge (Ab_{km \max} > p_{qm})\} \right) = M; \\ 0, & \left(\sum_{m=1}^M \{1 | (Ab_{km \min} < p_{qm}) \wedge (Ab_{km \max} > p_{qm})\} \right) \neq M, \end{cases} \quad (2.43)$$

де сума $\sum_{m=1}^M \{1 | (Ab_{km \min} < p_{qm}) \wedge (Ab_{km \max} > p_{qm})\}$ визначає кількість відповідностей значень ознак p_{qm} q -го екземпляра кандидату Ab_k . Якщо

$\left(\sum_{m=1}^M \{1 | (Ab_{km \min} < p_{qm}) \wedge (Ab_{km \max} > p_{qm})\} \right) = M$, то вважається, що екземпляр

$s_q = \langle p_{qm}, t_q \rangle$ відповідає кандидату в детектори Ab_k (знаходиться усередині простору гіперкуба з координатами $Ab_{1 \min} = \{Ab_{11 \min}, Ab_{12 \min}, \dots, Ab_{1M \min}\}$ і $Ab_{1 \max} = \{Ab_{11 \max}, Ab_{12 \max}, \dots, Ab_{1M \max}\}$).

Якщо існує хоча б один екземпляр $s_q = \langle p_{qm}, t_q = t'_1 \rangle \in S_1$, для якого $eq(Ab_k, s_q) = 1$, то вважається, що кандидат Ab_k активується при зіставленні з екземпляром s_q і, отже, не може бути детектором.

Тому при виконанні умови (2.44)

$$\exists s_q \in S_1 : eq(Ab_k, s_q) = 1 \quad (2.44)$$

відбувається етап донавчання кандидата Ab_k . Метою даного етапу є перетворення кандидата в детектори Ab_k таким чином, щоб у вибірці S_1 не існувало екземплярів, при зіставленні з якими відбувалася би активація детектора Ab_k .

Для цього вибирається кортеж однієї з ознак $Ab_{km} = \langle Ab_{km \min}, Ab_{km \max} \rangle$, по яких кандидат у детектори Ab_k збігається з екземпляром s_q . Далі перетворюється одне з граничних значень m -ї ознаки кандидата Ab_k :

$$Ab_{km \min} = p_{qm} + \eta_n (Ab_{km \max} - p_{qm}), \quad (2.45)$$

$$Ab_{km \max} = p_{qm} - \eta_n (p_{qm} - Ab_{km \min}). \quad (2.46)$$

При цьому формула (2.45) застосовується при виконанні умови $rnd > 0,5$ ($rnd = rand[0;1)$ – випадково згенероване число в діапазоні $[0;1)$), у протилежному випадку застосовується формула (2.46). У результаті перетворень (2.45) та (2.46) об'єм гіперкуба Ab_k зменшується таким чином, що екземпляр s_q розташовується поза простором, який описується кандидатом у детектори Ab_k . Коефіцієнт $0 \leq \eta_n < 1$ задається користувачем як параметр методу або може генеруватися випадковим чином. Чим більше значення даного коефіцієнта, тим більше відстань між екземплярами вибірки S_1 і гіперкубом детектора Ab_k .

Після перетворення граничних значень $Ab_{km} = \langle Ab_{km \min}, Ab_{km \max} \rangle$ однієї з ознак кандидата в детектори Ab_k , він повторно перевіряється з кожним екземпляром вибірки S_1 на виконання умови (2.44). При виконанні умови (2.44) аналогічним чином відбувається повторне перетворення граничних значень однієї з ознак кандидата Ab_k . І так доти, поки буде виконуватися умова (2.44).

Після того, як у множині $S_1 = \langle P, T = t_1 \rangle$ не залишиться екземплярів s_q , при зіставленні з якими активізується кандидат Ab_k , виконується етап

оцінювання пристосованості кандидата Ab_k до узагальнення. При використанні принципів негативного відбору формується множина детекторів $AB_1 = \{Ab_1, Ab_2, \dots, Ab_{N_{Ab}}\}$, що дозволяють з високою точністю визначити належність екземплярів s_q вибірки S до визначеного класу [174–186]. Тому як критерій оцінювання будемо використовувати характеристики (2.47) і (2.48), що дозволяють оцінити здатність детектора Ab_k до узагальнення даних:

$$G_1(Ab_k) = \frac{1}{M} \sum_{m=1}^M \frac{Ab_{km\max} - Ab_{km\min}}{p_{m\max} - p_{m\min}}, \quad (2.47)$$

$$G_2(Ab_k) = \frac{\prod_{m=1}^M (Ab_{km\max} - Ab_{km\min})}{\prod_{m=1}^M (p_{m\max} - p_{m\min})}, \quad (2.48)$$

де $p_{m\min} = \min_{q=1,2,\dots,Q_1} (p_{qm})$ та $p_{m\max} = \max_{q=1,2,\dots,Q_1} (p_{qm})$ – мінімальне і максимальне значення m -ї ознаки у вибірці S_1 , відповідно.

Критерії (2.47) і (2.48) відображають частину простору пошуку, що покривається за допомогою детектора. Критерій $G_1(Ab_k)$ показує середню частку простору, що покривається детектором, у кожному з M вимірів простору ознак. Критерій $G_2(Ab_k)$ відображає об'ємну частину простору, що покривається.

Чим більше значення критеріїв $G_1(Ab_k)$ і $G_2(Ab_k)$, тим більш велику частину простору пошуку покриває детектор. Отже, якщо значення критерію оцінювання якості узагальнення $G(Ab_k)$ вище граничного G_{\min} ($G(Ab_k) > G_{\min}$), то вважається, що кандидат Ab_k характеризується високими узагальнювальними властивостями, може бути детектором і додається у множину детекторів: $AB_1 = AB_1 \cup \{Ab_k\}$.

Створення нових кандидатів Ab_k здійснюється доти, поки не буде досягнуто критеріїв закінчення пошуку. Як такі критерії можуть бути використані точність розпізнавання $E(S)$, досягнення максимально припустимої кількості детекторів ($N_{Ab} = |AB| > N_{Ab_{max}}$), перевищення максимально припустимого часу пошуку ($t > t_{max}$).

Отриманий у результаті негативного відбору набір детекторів $AB_1 = \{Ab_1, Ab_2, \dots, Ab_{N_{Ab}}\}$ описує область простору пошуку $\overline{S_1}$, комплементарну області простору, у якій розташована множина «своїх» екземплярів S_1 . При цьому множина $AB_1 = \{Ab_1, Ab_2, \dots, Ab_{N_{Ab}}\}$ характеризується високими апроксимаційними й узагальнювальними здібностями.

Аналогічним чином можна сформувати набір детекторів AB_0 для множини S_0 . Проте, у задачах з нерівномірним розподілом екземплярів класів вибірки $S = \langle P, T \rangle$, коли кількість екземплярів одного класу $Q_1 = N_{t_q=t'_1}$ суттєво перевищує кількість екземплярів іншого класу $Q_0 = N_{t_q=t'_0}$ ($Q_0 \ll Q_1$), можуть виникнути проблеми з генерацією детекторів, що адекватно відображають простір екземплярів S_0 (можуть бути згенеровані детектори Ab_k у вигляді гіперкубів занадто великого обсягу, що не зможуть узагальнити дані генеральної сукупності). Це обумовлено невеликою (недостатньою) кількістю екземплярів у вибірці S_0 ($Q_0 \ll Q_1$), а іноді і майже повною їхньою відсутністю.

Тому при генерації детекторів для екземплярів S_0 пропонується використовувати інформацію про розміри детекторів, побудованих на основі вибірки S_1 . При цьому детектори будуть відображати інформацію про наявність у гіперкубі екземплярів вибірки S_0 (а не про їхню відсутність, як при класичному негативному відборі), і, отже, по суті будуть цілком відповідати детекторам, які побудовані раніше для вибірки S_1 на основі негативного

відбору та містять інформацію про області простору пошуку, у яких не розташовуються екземпляри S_1 .

Детектори $Ab_k^{(0)}$ вибірки S_0 генеруються таким чином, щоб їхні центри відповідали координатам екземплярів $s_k = \langle p_{km}, t_k = t'_0 \rangle \in S_0$ вибірки S_0 , а розміри граней їхніх гіперкубів відповідали аналогічним розмірам детекторів, створених на основі даних вибірки S_1 . Отже, координати детектора $Ab_{km}^{(0)} = \langle Ab_{km\min}^{(0)}, Ab_{km\max}^{(0)} \rangle$ визначаються за формулами (2.49)–(2.50):

$$Ab_{km\min}^{(0)} = p_{km} - \frac{1}{2} \Delta Ab_m, \quad (2.49)$$

$$Ab_{km\max}^{(0)} = p_{km} + \frac{1}{2} \Delta Ab_m, \quad (2.50)$$

де ΔAb_m – середня довжина граней детекторів $AB_1 = \{Ab_1, Ab_2, \dots, Ab_{N_{Ab}}\}$, створених на основі множини S_1 . Величину ΔAb_m пропонується обчислювати, виходячи з інформації про детектори $AB_1 = \{Ab_1, Ab_2, \dots, Ab_{N_{Ab}}\}$, використовуючи формулу (2.51):

$$\Delta Ab_m = \frac{1}{N_{Ab} M} \left(\sum_{k=1}^{N_{Ab}} \sum_{m=1}^M (Ab_{km\max} - Ab_{km\min}) \right). \quad (2.51)$$

Потім виконується зіставлення згенерованих детекторів $Ab_k^{(0)}$ з екземплярами вибірки S_1 , використовуючи формулу (2.43), при виконанні умови (2.44) відбувається перетворення детекторів $Ab_k^{(0)}$ аналогічно описаному вище етапу донавчання. Після цього обчислюється значення одного з критеріїв $G(Ab_k^{(0)})$ оцінювання здатності детектора до узагальнення даних (2.47)–(2.48), і,

у випадку, якщо його значення вище граничного, детектор $Ab_k^{(0)}$ додається у множину $AB_0 = AB_0 \cup \{Ab_k^{(0)}\}$.

У такий спосіб генерується набір детекторів AB_0 , який описує, як і набір AB_1 , область простору пошуку \bar{S}_1 , комплементарну області розташування множини екземплярів S_1 . Тому розпізнавальна модель може бути подана у вигляді множини детекторів $AB = AB_0 \cup AB_1$, що дозволяють розпізнавати належність невідомих екземплярів $s'_q = \langle p'_{qm}, t'_q - ? \rangle \notin S$ до класу «чужих», тобто відносити їх до класу $t'_0: t'_q = t'_0$.

З метою підвищення рівня інтерпретовності отриманої розпізнавальної моделі, поданої у вигляді набору детекторів $AB = \{Ab_1, Ab_2, \dots, Ab_{N_{Ab}}\}$, пропонується на основі набору AB сформуванню множини продукційних правил $PR_r: P_r \rightarrow T_r$, у яких ліва частина P_r імплікації являє собою набір умов вигляду (2.52):

$$\begin{aligned} & \text{Якщо } (p_1 \in [Ab_{k1 \min}; Ab_{k1 \max}]) \wedge \\ & \wedge (p_2 \in [Ab_{k2 \min}; Ab_{k2 \max}]) \wedge \dots \wedge (p_M \in [Ab_{kM \min}; Ab_{kM \max}]), \end{aligned} \quad (2.52)$$

а права частина T_r містить значення вихідного параметра T при виконанні r -го набору умов P_r (2.52).

При формуванні набору правил PR в антецедент правила P_r будемо включати тільки ті границі ознак, для яких вони не є граничними значеннями, тобто $Ab_{km \min} \neq \min_{q=1,2,\dots,Q} (p_{qm})$ і $Ab_{km \max} \neq \max_{q=1,2,\dots,Q} (p_{qm})$. Наприклад, для детектора виду $Ab_k = \{\langle 5, 7 \rangle, \langle 8, p_{2 \max} \rangle, \langle p_{3 \min}, p_{3 \max} \rangle, \langle 4, 6 \rangle\}$ буде сформовано правило PR_k виду: Якщо $(p_1 > 5 \wedge p_1 < 7) \wedge (p_2 > 8) \wedge (p_4 > 4 \wedge p_4 < 6)$, то віднести екземпляр до класу «чужих» ($T \neq t_1$). Як видно, у правило не ввійшли в явному вигляді верхня границя ознаки p_2 і цілком ознака p_3 , оскільки

відповідні значення детектора знаходяться на мінімальній і максимальній границях ознак і не впливають на якість розпізнавання. Крім того, виключення таких значень із правила PR_k знижує його складність, підвищуючи в такий спосіб інтерпретовність правила.

Використовуючи такий підхід, на основі кожного k -го детектора Ab_k виконується побудова свого правила, формуючи в такий спосіб множину PR , що складається з N_{Ab} продукційних правил $PR_r : P_r \rightarrow T_r$.

Для оцінювання часової складності O_{NS} запропонованого методу синтезу продукційних правил на основі негативного відбору визначимо кількість елементарних операцій, виконуваних на кожному етапі методу.

Розроблений метод передбачає на початковому етапі виконання процесу оцінювання значущості ознак p_m по відношенню до вихідного параметра T . Даний процес пов'язаний з необхідністю обробки множини $S = \langle P, T \rangle$. Складність цього етапу може бути оцінена як $O_{inf} = O(MQ)$.

Процес побудови множини детекторів передбачає необхідність оцінювання кожного кандидата в детектори Ab_k , обробляючи при цьому вибірку $S = \langle P, T \rangle$. Крім того, у випадку неможливості включення кандидата Ab_k в список детекторів AB (при виконанні умови (2.44)), виконується етап донавчання детектора і повторного його оцінювання. Тому складність даного етапу визначимо по формулі: $O_{AB} = O(MQ^2 N_{Ab_{max}})$, де $N_{Ab_{max}}$ – максимально припустима кількість детекторів.

Обчислювальну часову складність запропонованого методу оцінимо в такий спосіб: $O_{NS} = O_{inf} + O_{AB} = O(MQ) + O(MQ^2 N_{Ab_{max}}) = O(MQ^2 N_{Ab_{max}})$.

Для оцінювання просторової складності O_{NSp} запропонованого методу синтезу продукційних правил на основі негативного відбору визначимо кількість комірок пам'яті, необхідну для його функціонування. Розроблений

метод передбачає необхідність обробки та збереження інформації про навчальну множину $S = \langle P, T \rangle$ і значення оцінок індивідуальних інформативностей ознак, на що буде потрібно $O(MQ + M)$ комірок пам'яті. Крім того, необхідно передбачити пам'ять для збереження інформації про синтезовані набори детекторів AB_1 і AB_0 , де кожен детектор $Ab \in AB$ являє собою кортеж виду $Ab = \langle Ab_{\min}, Ab_{\max} \rangle$, $Ab_{\min} = \{Ab_{1\min}, Ab_{2\min}, \dots, Ab_{M\min}\}$, $Ab_{\max} = \{Ab_{1\max}, Ab_{2\max}, \dots, Ab_{M\max}\}$. На збереження інформації про набори детекторів $Ab \in AB$ може знадобитися $O(2MN_{Ab_{\max}})$ комірок пам'яті.

Отже, просторова складність запропонованого методу може бути оцінена так: $O_{NSp} = O(MQ + M + 2MN_{Ab_{\max}})$.

Таким чином, запропонований метод синтезу продукційних правил на основі негативного відбору для випадку нерівномірного розподілу екземплярів класів вибірки при генерації набору детекторів використовує відому інформацію про екземпляри всіх класів вибірки, враховує інформацію про індивідуальну значущість ознак, як форму детектора використовує гіперкуб максимально можливого обсягу, що дозволяє виключати малозначущі і надлишкові ознаки з вибірки, скоротивши тим самим простір пошуку і час виконання методу, а також формувати набір детекторів з високими апроксимаційними й узагальнювальними здібностями.

Запропонований метод за рахунок підвищення узагальнювальних властивостей синтезованих моделей шляхом скорочення кількості детекторів та умов антецедентів також підвищує інтерпретовність моделі, скорочує її розмірність (структурну і параметричну складність), обсяг використовуваної пам'яті і підвищує швидкодію моделі при послідовній реалізації обчислень.

2.4 Висновки за розділом 2

У розділі вирішено актуальну задачу автоматизації видобування знань з навчальних вибірок даних для побудови діагностичних моделей на основі інтелектуальних обчислень. Запропоновано методи видобування знань для побудови діагностичних моделей на основі дерев розв'язків, асоціативних правил та негативного відбору, які дозволяють витягати з заданих вибірок даних набори правил, що можуть використовуватися як базис для структурного синтезу діагностичних моделей на основі нейро-нечітких мереж.

Розроблено стохастичний метод синтезу моделей на основі дерев розв'язків, який використовує інформацію про інформативність ознак, складність синтезованого дерева, а також точність його розпізнавання, що дозволяє на початковому етапі формувати множину деревоподібних структур, яка характеризується простою ієрархією та невисокою помилкою розпізнавання, у процесі пошуку створювати нові множини розв'язків з урахуванням інформації про значущість ознак і інтерпретовність генерованих дерев, що, у свою чергу, забезпечує можливість побудови дерева розв'язків з невеликою кількістю елементів (вузлів і зв'язків між ними) та прийнятною точністю розпізнавання, а також видобування на його основі найцінніші екземпляри для структурного синтезу діагностичних моделей. Запропоновано систему критеріїв оцінювання моделей на основі дерев розв'язків, що містить у собі критерії оцінювання апроксимаційних властивостей (помилка розпізнавання) і інтерпретовності (ширина, глибина, гіллястість, узагальнення рішень, узагальнення моделі, внутрилстовна відстань) синтезованого дерева.

Запропоновано стохастичний метод видобування чисельних асоціативних правил, що передбачає попереднє розбиття значень ознак на інтервали (терми), враховує при цьому ширину діапазону значень і частоту попадання ознак у кожний з термів, використовує імовірнісний підхід для

перебору різних сполучень антецедентів і консеквентів асоціативних правил, використовує апіорну інформацію про значущість термів і ознак, що дозволяє обробляти чисельну інформацію при видобуванні асоціативних правил, не здійснювати істотну кількість проходів по заданій базі транзакцій, виявляти правила з високим рівнем вірогідності й інших критеріїв оцінювання їхньої якості. Запропоновано систему критеріїв, яка дозволяє враховувати різні характеристики асоціативних правил, що характеризують їхню вірогідність, частоту виконання, інформативність та інтерпретовність. Розроблена система критеріїв може бути використана для автоматизації аналізу властивостей і порівняння моделей на основі асоціативних правил при вирішенні задач діагностування, розпізнавання образів і неруйнівного контролю якості.

Запропоновано метод синтезу продукційних правил на основі негативного відбору для випадку нерівномірного розподілу екземплярів класів вибірки, який при генерації набору детекторів використовує відому інформацію про екземпляри всіх класів вибірки, враховує інформацію про індивідуальну значущість ознак, як форму детектора використовує гіперкуб максимально можливого об'єму, що дозволяє виключати малозначущі та надлишкові ознаки з вибірки, скоротивши тим самим простір пошуку і час виконання методу, а також формувати набір детекторів з високими апроксимаційними й узагальнювальними здібностями. Запропонований метод за рахунок підвищення узагальнювальних властивостей синтезованих моделей шляхом скорочення кількості детекторів та умов антецедентів також підвищує інтерпретовність моделі, скорочує її розмірність (структурну і параметричну складність), обсяг використовуваної пам'яті та підвищує швидкодію моделі при послідовній реалізації обчислень.

Список використаних джерел у цьому розділі наведено у повному списку використаних джерел під номерами [6–10, 45, 47, 48, 57–63, 75–89, 97, 98, 106, 108, 109, 115, 126–141, 164–211, 264, 267–285].

3 ПАРАЛЕЛЬНИЙ ПІДХІД ДО ВИДОБУВАННЯ ЗНАНЬ ПРИ ОБРОБЦІ ВЕЛИКИХ ВИБІРОК ДАНИХ ДЛЯ ПОБУДОВИ ДІАГНОСТИЧНИХ МОДЕЛЕЙ

При розв'язанні задач діагностування й автоматичної класифікації часто необхідно не тільки забезпечити точне прийняття рішень, але і пояснити те, як і чому прийняте рішення. Тому виникає потреба побудови зручних для сприйняття та наступного аналізу моделей.

Найбільш зручними для сприйняття й аналізу людиною моделями є набори продукційних правил [57–63, 220–228]. Такі правила можна використовувати як базис в процесі структурного синтезу діагностичних моделей на основі нейро-нечітких мереж. Формування продукційних правил людьми пов'язано із суб'єктивністю та неточністю, а також обмежено добре вивченими задачами невеликої розмірності. Тому виникає потреба в побудові інтерпретованих моделей на основі продукційних правил по набору прецедентів – експериментально отриманих спостережень за досліджуваними об'єктами або процесами.

Для побудови бази правил на основі наявних вибірок даних використовують, як правило, підходи, засновані на копіюванні вибірки в базу правил, скороченні і редукації правил [45, 97, 220–228]. Це вимагає значних ресурсних витрат на обробку даних, пов'язаних з необхідністю перебору різних наборів правил, і не дозволяє синтезувати моделі у виді наборів продукцій з високим рівнем узагальнення даних унаслідок того, що синтезовані в такий спосіб бази правил, як правило, характеризуються значною надмірністю або специфічністю.

Для усунення зазначених недоліків запропоновано [274–285] методи видобування продукційних правил на основі парадигм обчислювального інтелекту: дерев розв'язків, асоціативних правил, негативного відбору).

Запропоновані методи показали свою ефективність при використанні на різних вибірках даних. Високу ефективність при обробці великих вибірок з дубляжем інформації, що містять велику кількість ознак і екземплярів, у т.ч. надлишкових, показав метод видобування правил на основі дерев розв'язків. При обробці наборів даних з великою кількістю пропущених значень або вибірок, поданих у вигляді баз транзакцій, доцільним є використання методу на основі асоціативних правил. У випадках нерівномірного розподілу екземплярів по класах вибірки для видобування продукційних правил ефективно може застосовуватися метод на основі негативного відбору, що дозволяє виявляти аномалії або випадкові зміни в діагностованих об'єктах.

Однак існує ряд задач, у яких потрібно постійно переобчислювати параметри синтезованих моделей (чи синтезувати нові моделі) у зв'язку з постійним збільшенням або одержанням нових даних про досліджувані об'єкти чи процеси, або через зміну досліджуваних об'єктів чи їхнього стану. До таких задач, наприклад, відносяться задачі індивідуального прогнозування станів пацієнтів, у яких необхідно синтезувати діагностичні моделі для кожного пацієнта окремо і постійно їх модифікувати в зв'язку з тим, що постійно оновлюється інформація (збільшуються її обсяги) в результаті безупинного спостереження за станом здоров'я. Це вимагає значних витрат апаратних ресурсів та часу роботи комп'ютера. Крім того, оновлювані і розширювані в результаті безупинних спостережень і досліджень вибірки даних можуть змінювати свої властивості та характеристики, наприклад, у них можуть з'являтися пропущені дані для деяких ознак або накопичуватися надлишкова інформація. Це ускладнює застосування на практиці методів, запропонованих у попередньому розділі, оскільки не завжди фахівцю в прикладній області зрозуміло, який саме метод і при яких умовах доцільно використовувати. Таким чином, необхідність усунення недоліків, пов'язаних із змінюваними властивостями вибірок даних у процесі їхнього оновлення та розширення, а також з високими вимогами до апаратних ресурсів і ресурсів часу, виникає

потреба розробки методу видобування продукційних правил, вільного від зазначених недоліків. Обробку заданих наборів даних пропонується здійснювати шляхом розпаралелювання процесу функціонування методів обчислювального інтелекту для видобування продукційних правил, внаслідок чого розроблено метод видобування продукційних правил на основі паралельної побудови інтелектуальних моделей, що узагальнюють задані вибірки даних у виді моделей на основі дерев розв'язків, асоціативних правил, негативного відбору.

3.1 Паралельний метод видобування продукційних правил на основі обчислювального інтелекту

Як базис для паралельного методу видобування продукційних правил будемо використовувати методи на основі дерев розв'язків, асоціативних правил, негативного відбору, запропоновані у попередньому розділі. Для цього виділимо основні операції кожного методу, які можна виконувати паралельно.

3.1.1 Застосування дерев розв'язків для видобування продукційних правил у паралельному режимі

При видобуванні продукційних правил за допомогою методу на основі дерев розв'язків [274] найбільш ресурсномісткими і такими, які доцільно розпаралелити, є наступні операції:

– генерація початкової множини дерев розв'язків $R^{(0)} = \{\chi_1^{(0)}, \chi_2^{(0)}, \dots, \chi_{N_\chi}^{(0)}\}$

пов'язана з необхідністю побудови набору, що складається з N_χ

деревоподібних структур, для кожної з яких χ_k необхідно визначити набір взаємозалежних вузлів d_{ab} , що містять інформацію про ознаку p_{mab} , по якій відбувається розбиття, її граничне значення p_{TRab} , а також посилання на лівого $d_{(a+1)(2b-1)}$ і правого $d_{(a+1)(2b)}$ нащадків: $d_{ab} = \langle p_{mab}, p_{TRab}, d_{(a+1)(2b-1)}, d_{(a+1)(2b)} \rangle$, з урахуванням при цьому апріорної інформації про значущість ознак V_m ;

– обчислення значень множини функцій $G = G(\chi_k)$, що враховують інтерпретовність $Int(\chi_k)$ та здібності до розпізнавання $E(\chi_k)$ деревоподібних структур χ_k ;

– формування нових множин рішень $\chi_k^{(i+1)}$ за допомогою операторів схрещування і мутації, що припускають переформатування деревоподібних структур $\chi_k^{(i)}$ за визначеними правилами, пов'язаними зі зміною структури дерева $\chi_k^{(i)}$ і необхідністю повторного обчислення його параметрів (граничних значень ознак-перевірок p_{mab}).

З огляду на вищевикладене й особливості методу [274], узагальнено модель видобування продукційних правил на основі дерев у паралельній формі [286] можна подати у виді, зображеному на рис. 3.1.

Позначимо: N_{DTpr} – кількість процесів паралельної системи, використовуваних для побудови дерев розв'язків за допомогою методу [274]; $|R^{(i,j)}| = N_{\chi_{pr}}$ – кількість рішень $\chi_k^{(i,j)}$, оброблюваних на кожному процесі паралельної системи; $R^{(i',j)} = Cross(R^{(i,j)})$ – множина рішень $\chi_k^{(i',j)}$, згенерованих на основі множини $R^{(i,j)}$ за допомогою оператора схрещування $Cross(R^{(i,j)})$, $j = 1, 2, \dots, N_{DTprCr}$; N_{DTprCr} – кількість процесів паралельної системи, що використовуються для генерації нових рішень за допомогою оператора схрещування; $R^{(i',j)} = Mut(R^{(i,j)})$ – множина рішень $\chi_k^{(i',j)}$, згенерованих на основі множини $R^{(i,j)}$ за допомогою оператора мутації $Mut(R^{(i,j)})$.

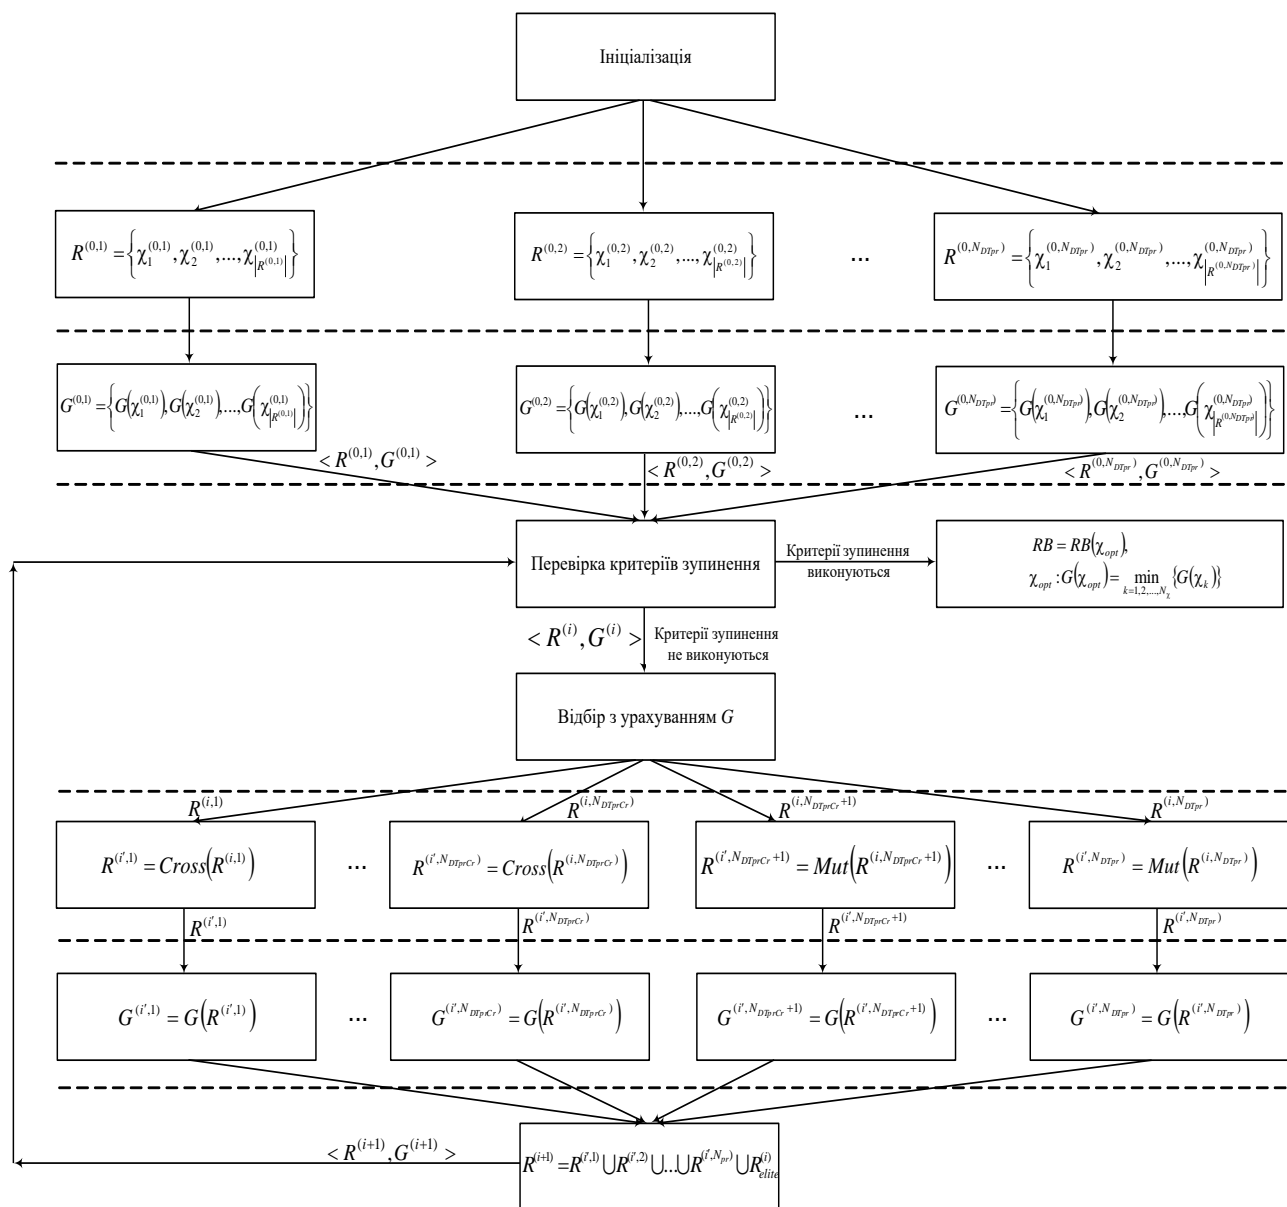


Рисунок 3.1 – Модель процесу видобування продукційних правил за допомогою методу на основі дерев розв’язків у паралельній формі

Як видно з рис. 3.1, на початковому етапі відбувається ініціалізація методу. При цьому задається навчальна вибірка $S = \langle P, T \rangle$ і відбувається оцінювання значущості V_m ознак p_m ($m = 1, 2, \dots, M$). Паралельно виконуються етапи методу [274], пов’язані зі створенням початкової множини дерев розв’язків $R^{(0)} = \{\chi_1^{(0)}, \chi_2^{(0)}, \dots, \chi_{N_\chi}^{(0)}\}$, оцінюванням поточної множини рішень (обчислення значень цільової функції $G = G(\chi_k)$), а також створенням нових

рішень $\chi_k^{(i+1)}$ на основі операторів схрещування $Cross(R^{(i,j)})$ і мутації $Mut(R^{(i,j)})$.

При цьому на початковому етапі при генерації множини рішень $R^{(0)} = \{\chi_1^{(0)}, \chi_2^{(0)}, \dots, \chi_{N_\chi}^{(0)}\}$ на кожному процесорі паралельної системи створюється й оцінюється $N_{\chi pr}$ рішень (3.1):

$$N_{\chi pr} = \text{div}\left(\frac{N_\chi}{N_{DTpr}}\right), \quad (3.1)$$

де N_χ – загальна кількість рішень, оброблюваних в процесі стохастичного пошуку;

$\text{div}(a)$ – функція, що повертає цілу частину числа a .

З метою усунення можливого зменшення загальної кількості рішень N_χ (параметр, що задається користувачем у процесі ініціалізації методу [274]) внаслідок округлення при виконанні операції $\text{div}(a)$, пропонується збільшити на одиницю кількість оброблюваних рішень $N_{\chi pr}$ на перших $\text{mod}\left(\frac{N_\chi}{N_{DTpr}}\right)$ процесорах, де $\text{mod}(a)$ – функція, що повертає залишок від ділення виразу a .

Потім на головному процесі відбувається перевірка критеріїв зупинення, у випадку задоволення яких на основі найбільш прийняттого рішення $\chi_{opt} : G(\chi_{opt}) = \min_{k=1,2,\dots,N_\chi} \{G(\chi_k)\}$ створюється набір продукційних правил $RB = RB(\chi_{opt})$.

При невиконанні критеріїв зупинення відбувається відбір рішень з урахуванням значень їхніх цільових функцій. Після цього в паралельному режимі за допомогою операторів схрещування $Cross(R^{(i,j)})$ і мутації $Mut(R^{(i,j)})$ відбувається створення нової множини рішень $R^{(i+1)}$.

Кількість процесів паралельної системи N_{DTprCr} , на яких будуть генеруватися нові рішення за допомогою оператора схрещування $Cross(R^{(i,j)})$, будемо встановлювати пропорційно кількості рішень N_{cross} , що повинні бути згенеровані за допомогою даного оператора. У методі [274] кількість N_{cross} визначається в такий спосіб: $N_{cross} = \beta N_{\chi}$, де β – параметр, що встановлюється користувачем на етапі ініціалізації, визначає значущість формування нової множини рішень за допомогою оператора $Cross(R^{(i,j)})$. Отже, кількість процесів N_{DTprCr} , використовуваних для роботи оператора схрещування, будемо визначати за формулою (3.2):

$$N_{DTprCr} = \text{div}(\beta N_{DTpr}). \quad (3.2)$$

Кількість процесів $N_{DTprMut}$, на яких будуть генеруватися нові рішення за допомогою оператора мутації $Mut(R^{(i,j)})$, будемо визначати за формулою (3.3):

$$N_{DTprMut} = N_{DTpr} - N_{DTprCr}. \quad (3.3)$$

Кількість рішень, створюваних на кожному процесі паралельної системи, за допомогою операторів схрещування і мутації може бути визначена за формулою (3.1).

Таким чином, запропонований підхід дозволяє виконувати розпаралелювання процесу узагальнення даних у вигляді ієрархічних деревоподібних моделей і видобування на їх основі продукційних правил.

3.1.2 Видобування продукційних правил на основі індукції асоціативних зв'язків

Як відзначено вище, обробку наборів даних, що містять велику кількість пропущених значень, а також вибірок, поданих у виді баз транзакцій, доцільно проводити на основі асоціативних правил [133–141, 279–282]. Ресурсномісткими і складними операціями стохастичного методу видобування чисельних асоціативних правил [282], що доцільно виконувати на різних вузлах паралельної системи, є наступні:

- розбиття діапазонів значень ознак p_m на інтервали Δp_{nm} , на основі яких визначаються терми ознак, враховуючи при цьому ширину діапазону значень і частоту попадання ознак у кожний з термів;

- оцінювання поточної множини рішень (асоціативних правил $A_k : P_k \rightarrow T_k$) шляхом обчислення вірогідності $\text{conf}(A_k)$ й інших критеріїв, що характеризують частоту виконання правил, їх інформативність й інтерпретовність. Цей процес пов'язаний з необхідністю виконання перетворень виду $\chi_k \rightarrow A_k$, у результаті чого на основі рішень χ_k створюються асоціативні правила $A_k : P_k \rightarrow T_k$. Крім того при оцінюванні кожного асоціативного правила A_k необхідно обробляти повний набір навчальних даних S , що вимагає істотних часових витрат;

- пошук оптимальних рішень за допомогою стохастичного підходу, кожна ітерація якого пов'язана з необхідністю створення нових рішень χ_k шляхом застосування операторів схрещування і мутації, для кожного з яких необхідно оцінити його якість $G(\chi_k)$.

Як видно, основні операції, виконувані при обробці транзакційних наборів даних за допомогою стохастичного підходу, аналогічні операціям процесу синтезу дерев розв'язків. Тому модель процесу обробки транзакційних

наборів даних у паралельній формі аналогічна моделі видобування продукційних правил за допомогою методу на основі дерев, наведеної на рис. 3.1. Виключення складає етап розбиття діапазонів значень ознак p_m на інтервали Δp_{nm} , що виконується на паралельних вузлах після ініціалізації методу (завдання користувачем початкових параметрів методу і навчального набору вхідних даних S) до створення початкової множини рішень $R^{(0)} = \{\chi_1^{(0)}, \chi_2^{(0)}, \dots, \chi_{N_\chi}^{(0)}\}$.

3.1.3 Виділення продукційних правил на основі негативного відбору

Видобування продукційних правил за допомогою методу на основі негативного відбору [285] доцільно виконувати при нерівномірному розподілі екземплярів по класах вибірки. Найбільш ресурсномісткими і такими, що потребують розпаралелювання, операціями методу видобування продукційних правил на основі негативного відбору [285] є:

– побудова й оцінювання набору детекторів $AB_1 = \{Ab_1, Ab_2, \dots, Ab_{N_{Ab}}\}$ на основі класу $T' = t'_1$, що дозволяють виявляти з невідомих екземплярів такі, які не відповідають класу t'_1 . При цьому ітеративно для кожного екземпляра s_q вибірки $S_1 = \langle P, T = t_1 \rangle$ визначається його відповідність кандидату в детектори $Ab_k = \langle Ab_{k \min}, Ab_{k \max} \rangle \in AB_1$ ($Ab_{k \min} = \{Ab_{k1 \min}, Ab_{k2 \min}, \dots, Ab_{kM \min}\}$, $Ab_{k \max} = \{Ab_{k1 \max}, Ab_{k2 \max}, \dots, Ab_{kM \max}\}$), у результаті чого часто потрібно виконання ресурсномісткого етапу донавчання кандидата Ab_k і перетворення його таким чином, щоб у вибірці S_1 не існувало екземплярів, при зіставленні з якими відбувалася б його активація. На кожному процесі паралельної системи так генерується $N_{Abpr} = N_{Ab} / N_{NSpr}$ детекторів, де N_{NSpr} – кількість процесів

паралельної системи, що використовуються для видобування продукційних правил за допомогою негативного відбору. Початкові значення параметрів кандидата в детектори [285] пропонується визначати за формулами (3.4)–(3.5):

$$Ab_{km \min} = \min_{q=1,2,\dots,|S_1|} (p_{qm}) + \text{rand} \left(0; \frac{1}{2N_{Abpr}} \text{iterAb} \right), \quad (3.4)$$

$$Ab_{km \max} = \max_{q=1,2,\dots,|S_1|} (p_{qm}) - \text{rand} \left(0; \frac{1}{2N_{Abpr}} \text{iterAb} \right), \quad (3.5)$$

де iterAb – номер створюваного детектора Ab_k на відповідному процесі паралельної системи.

Легко бачити, що формули (3.4)–(3.5) дозволяють створювати множину детекторів, розташованих у різних областях простору пошуку. При чому обсяг створюваних детекторів буде зменшуватися з номером ітерації, що дозволяє створювати детектори різних обсягів і більш детально досліджувати простір пошуку (перевіряючи як великі так і малі його обсяги);

– генерація й оцінювання набору детекторів $AB_0 = \{Ab_1^{(0)}, Ab_2^{(0)}, \dots, Ab_{N_{0Ab}}^{(0)}\}$ для множини S_0 на основі класу $T' = t'_0$ ($N_{0Ab} = |AB_0| \leq |S_0|$). При цьому як центри детекторів $Ab_k^{(0)}$ вибірки S_0 використовуються координати екземплярів $s_k = \langle p_{km}, t_k = t'_0 \rangle \in S_0$ вибірки S_0 , а як розміри граней їхніх гіперкубів – аналогічні розміри детекторів, створених на основі дані вибірки S_1 .

З огляду на особливості методу на основі негативного відбору, узагальнено модель видобування продукційних правил на основі негативного відбору в паралельній формі можна навести у вигляді, зображеному на рис. 3.2.

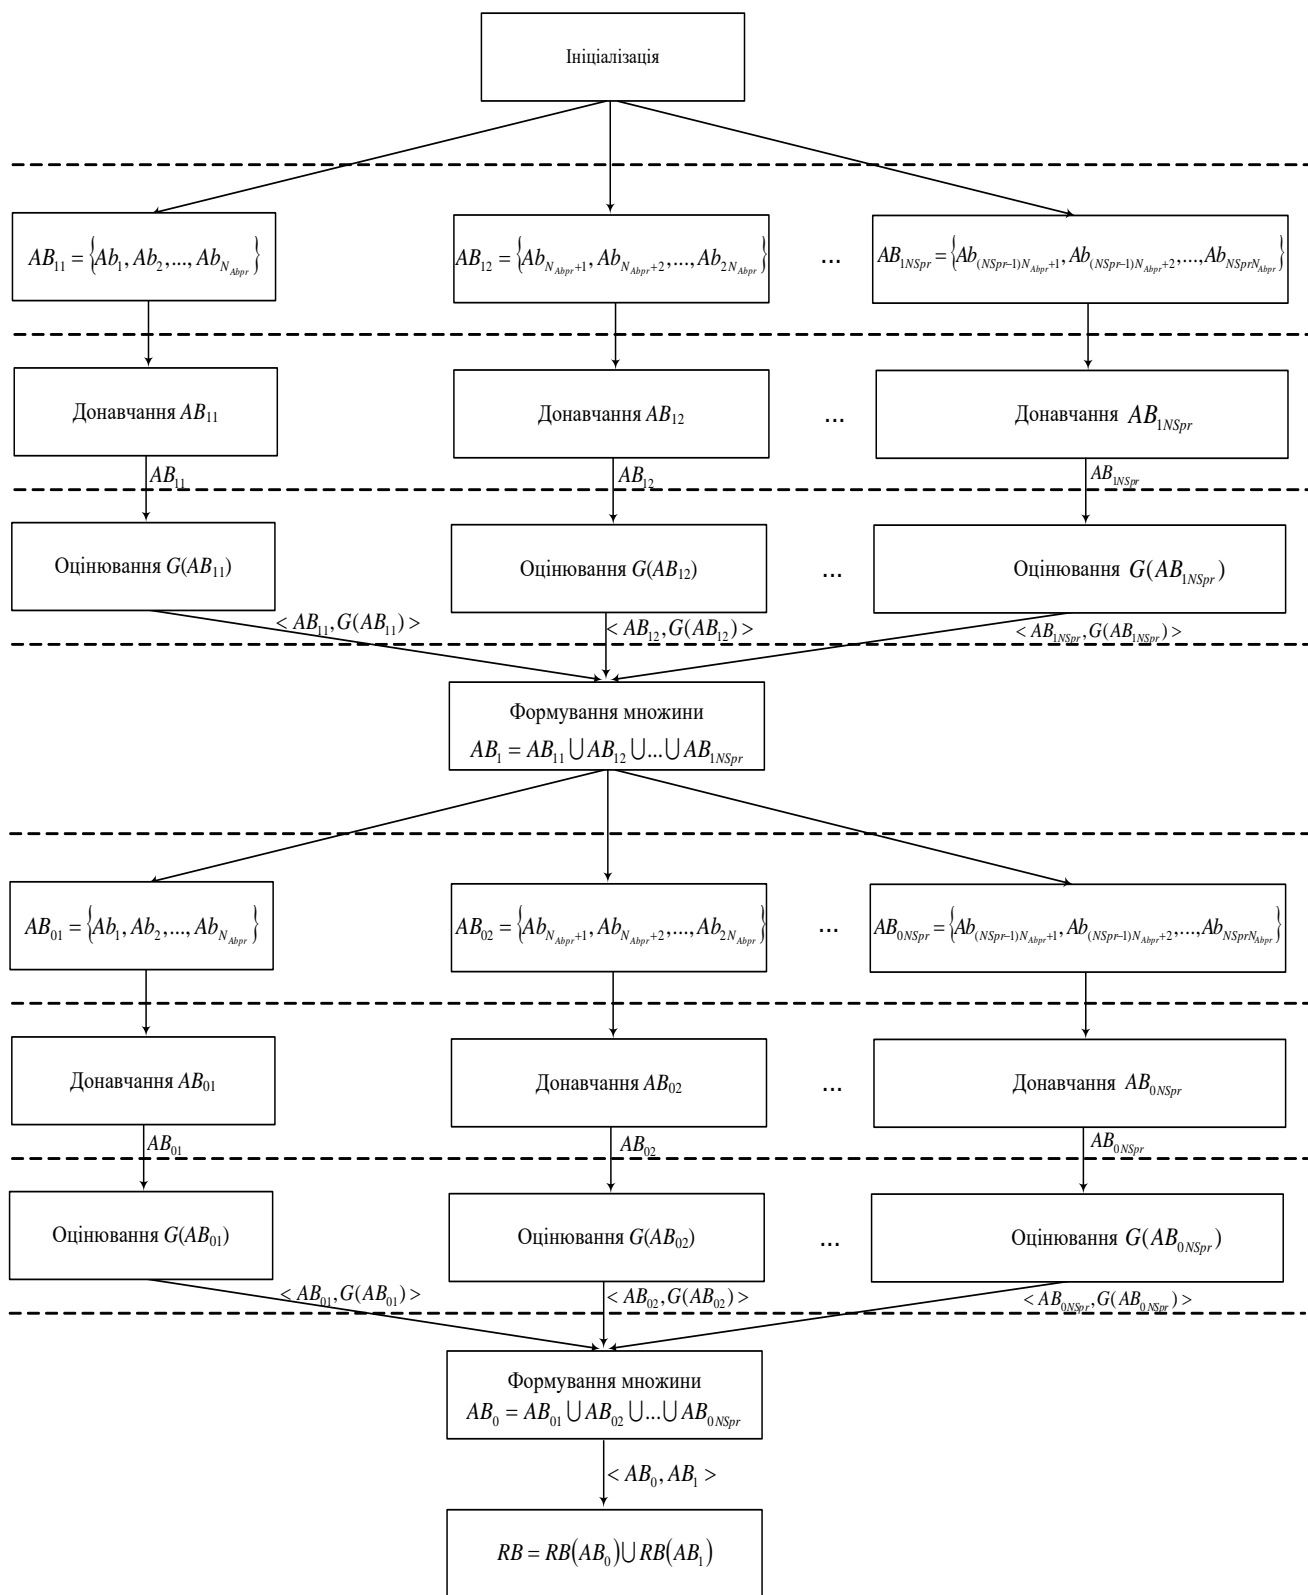


Рисунок 3.2 – Модель процесу видобування продукційних правил на основі негативного відбору в паралельній формі

Як видно, запропонована модель видобування продукційних правил передбачає розпаралелювання ресурсномістких процесів побудови детекторів, що дозволяють виявляти з невідомих екземплярів генеральної сукупності такі, які не відповідають визначеному класу.

3.1.4 Модель паралельного методу видобування продукційних правил на основі обчислювального інтелекту

Враховуючи й узагальнюючи вищесказане, наведемо на рис. 3.3 модель паралельного методу видобування продукційних правил на основі обчислювального інтелекту [286]. Пропонований метод передбачає паралельну побудову інтелектуальних моделей, що узагальнюють задані вибірки даних у виді моделей на основі дерев розв'язків, асоціативних правил, негативного відбору [287]. На рис. 3.3 за допомогою позначень $RB_{DT} = DT(S, V_m)$, $RB_{AR} = AR(S, \Delta p_{nm})$ та $RB_{NS} = NS(S, V_m)$ відображено процеси видобування продукційних правил на основі дерев розв'язків, асоціативних правил, негативного відбору, відповідно.

З рис. 3.3 видно, що паралельно виконується попередня обробка даних, що передбачає оцінювання значущості V_m ознак p_m стосовно вихідного параметра T , а також розбиття діапазонів значень ознак p_m на інтервали Δp_{nm} . Така інформація необхідна для подальшого видобування продукційних правил із заданих вибірок даних $S = \langle P, T \rangle$ на основі різних методів обчислювального інтелекту. Обчислення зазначених характеристик навчальних вибірок (V_m , Δp_{nm}) на різних вузлах паралельної системи дозволить істотно скоротити час виконання етапу попередньої обробки даних, що є особливо актуальним при вирішенні задач великої розмірності. Крім того, інформація про значущість

ознак V_m може бути використана в подальшому для виключення малозначущих ознак, скорочення в такий спосіб простору пошуку і, отже, часу виконання методу й обчислювальних ресурсів комп'ютера.

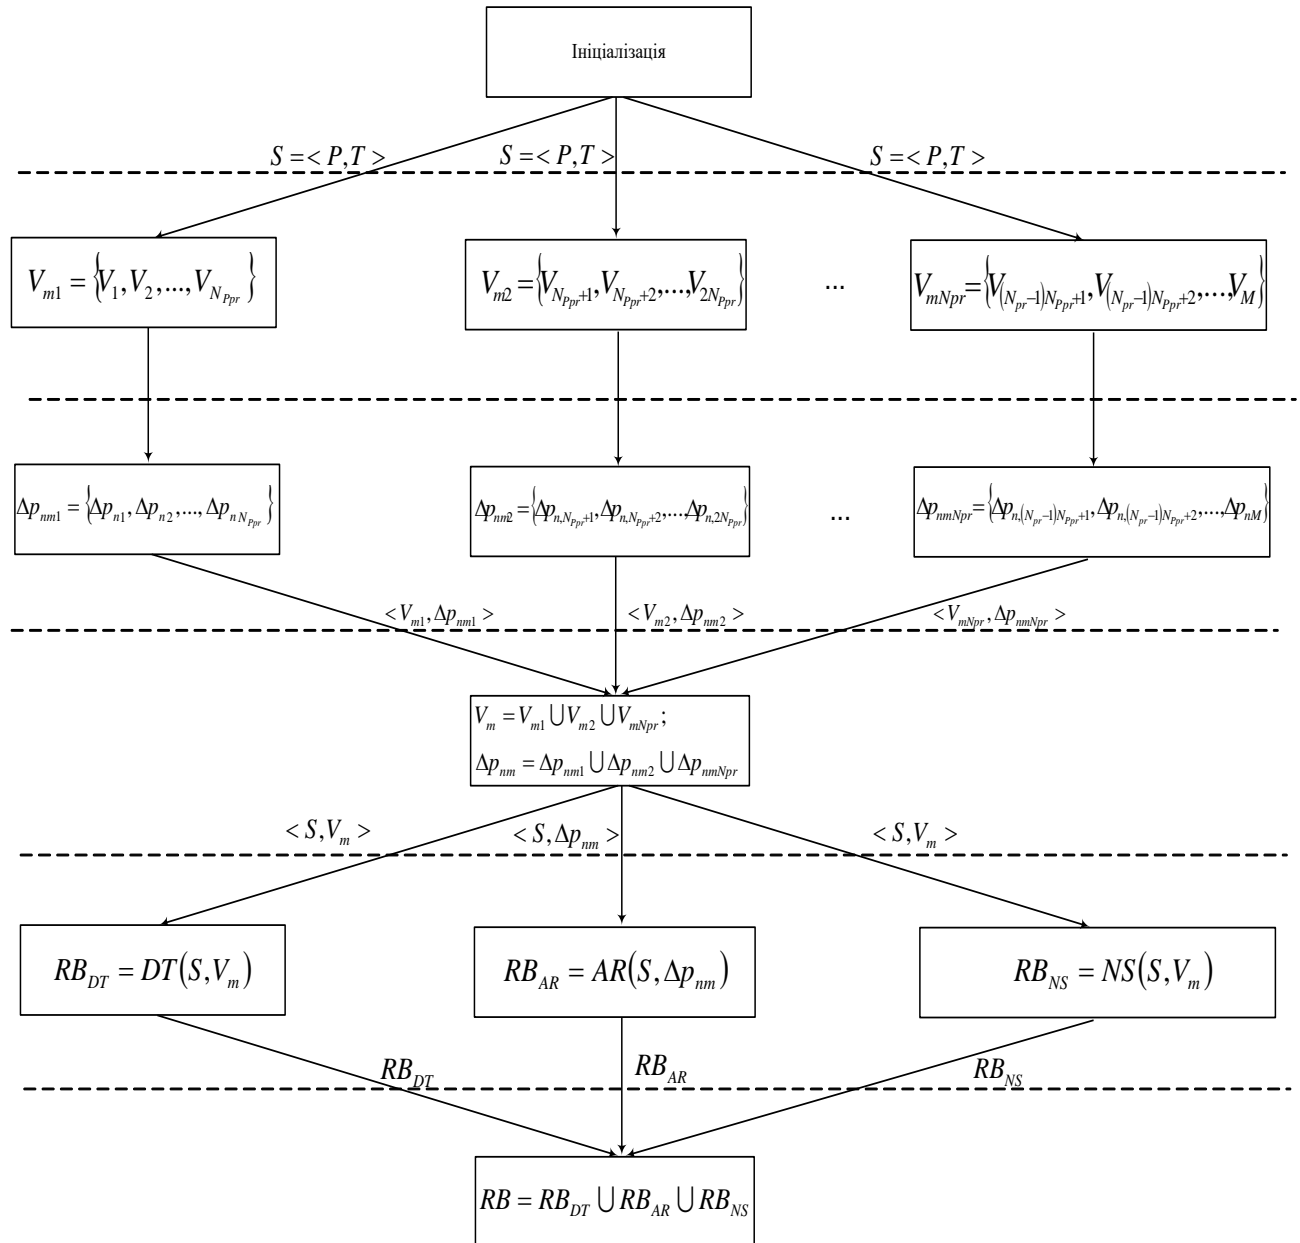


Рисунок 3.3 – Модель паралельного процесу видобування продукційних правил на основі обчислювального інтелекту

Також паралельно виконується ресурсномісткий етап видобування продукційних правил на основі запропонованих у попередньому розділі

методів. Для цього вузли паралельної системи розбиваються на три групи, у кожній з яких відбувається процес побудови бази продукційних правил на основі дерев розв'язків, асоціативних правил, негативного відбору, відповідно.

Таким чином, запропонований метод передбачає виконання таких етапів. На етапі ініціалізації користувач задає навчальну вибірку $S = \langle P, T \rangle$ і вводить основні параметри методу. Потім на вузлах паралельної системи відбувається попередня обробка даних, у результаті чого обчислюються оцінки інформативності V_m ознак p_m , і відбувається розбиття діапазонів значень ознак p_m на інтервали Δp_{nm} . На кожному процесі паралельної системи обчислюються оцінки V_m інформативності, і відбувається розбиття діапазонів Δp_{nm} для $N_{Pr} = \text{div}(M / N_{pr})$ ознак. Для усунення впливу похибки при округленні в наслідок виконання операції $\text{div}(a)$, на перших $\text{mod}(M / N_{pr})$ вузлах паралельної системи обробляється $N_{Pr} = 1 + \text{div}(M / N_{pr})$ ознак.

Після цього обчислені характеристики V_m , Δp_{nm} передаються на головний процес, з якого вони розподіляються між наявними вузлами паралельної системи для паралельного видобування продукційних правил на основі методів [274, 282, 285]. При цьому кількість процесів (вузлів) паралельної системи, що виділяються для видобування продукційних правил на основі дерев розв'язків, асоціативних правил, негативного відбору, визначається за формулами (3.6):

$$N_{DTpr} = \alpha_{DT} N_{pr}, \quad N_{ARpr} = \alpha_{AR} N_{pr}, \quad N_{NSpr} = \alpha_{NS} N_{pr}, \quad (3.6)$$

де α_{DT} , α_{AR} , α_{NS} – відносні частки кількості вузлів паралельної системи, використовуваних для видобування продукційних правил на основі дерев розв'язків, асоціативних правил, негативного відбору, відповідно.

Параметри α_{DT} , α_{AR} , α_{NS} задаються користувачем або визначаються експериментально шляхом вирішення тестових задач. При цьому очевидно, що повинні виконуватися рівності (3.7):

$$\alpha_{DT} + \alpha_{AR} + \alpha_{NS} = 1, \quad N_{DTpr} + N_{ARpr} + N_{NSpr} = N_{pr}. \quad (3.7)$$

Потім синтезовані бази продукційних правил RB_{DT} , RB_{AR} , RB_{NS} на основі дерев розв'язків, асоціативних правил і негативного відбору, відповідно, передаються на головний процес. На цьому процесі (вузлі паралельної системи) формується підсумкова база правил RB шляхом об'єднання правил RB_{DT} , RB_{AR} , RB_{NS} (3.8):

$$RB = RB_{DT} \cup RB_{AR} \cup RB_{NS}. \quad (3.8)$$

При цьому з метою виключення надмірності в базу RB додаються правила RB_i тільки один раз (правила, що присутні в декількох базах RB_{DT} , RB_{AR} , RB_{NS} , додаються тільки один раз).

Запропонований метод дозволяє істотно скоротити часові витрати на синтез моделей при вирішенні складних практичних задач, що характеризуються великими обсягами діагностичних даних, а також задач, де виникає необхідність у модифікації вже існуючих діагностичних і розпізнавальних моделей у зв'язку з постійно оновлюваною інформацією в результаті безупинного спостереження за станом досліджуваних об'єктів або процесів.

3.2 Теоретичний аналіз паралельного методу видобування продукційних правил

Оцінимо максимально можливе прискорення $Speedup_{pr}$ й ефективність паралельної системи $Efficiency_{pr}$ [288, 289] за допомогою закону Амдала [136–139] при використанні запропонованого методу на N_{pr} процесах паралельної системи.

Нехай α_{serial} – частка обчислень, що приходяться на послідовні етапи методу. Частку послідовних операцій методу α_{serial} визначимо за формулою (3.9):

$$\alpha_{serial} = \frac{N_{serial}}{N_{serial} + N_{paral}} = \frac{1}{1 + \frac{N_{paral}}{N_{serial}}}, \quad (3.9)$$

де N_{serial} – кількість операцій, що виконуються послідовно;

N_{paral} – кількість операцій, що виконуються на паралельних процесах.

Тоді оцінки максимально можливого прискорення й ефективності обчислювального процесу в паралельній системі можуть бути отримані за формулами (3.10), (3.11):

$$Speedup_{pr} = \frac{1}{\alpha_{serial} + \frac{1 - \alpha_{serial}}{N_{pr}}}, \quad (3.10)$$

$$Efficiency_{pr} = \frac{Speedup_{pr}}{N_{pr}}. \quad (3.11)$$

Для оцінювання величин $Speedup_{pr}$ і $Efficiency_{pr}$ визначимо значення характеристики α_{serial} запропонованого методу. Відзначимо, що виходячи з запропонованої моделі видобування продукційних правил на основі обчислювального інтелекту (рис. 3.3), процеси синтезу правил на основі дерев розв'язків $RB_{DT} = DT(S, V_m)$, асоціативних правил $RB_{AR} = AR(S, \Delta p_{nm})$ і негативного відбору $RB_{NS} = NS(S, V_m)$ також передбачають деяку частку послідовних операцій. Тому частку послідовних операцій запропонованого паралельного методу α_{serial} визначимо за формулою (3.12):

$$\alpha_{serial} = \alpha_{serialP} + \alpha_{serialDT} + \alpha_{serialAR} + \alpha_{serialNS}, \quad (3.12)$$

де $\alpha_{serialP}$ – частка послідовних операцій запропонованого методу, пов'язаних з ініціалізацією та формуванням підсумкової бази правил;

$\alpha_{serialDT}, \alpha_{serialAR}, \alpha_{serialNS}$ – частка послідовних операцій при видобуванні продукційних правил на основі дерев розв'язків, асоціативних правил і негативного відбору, відповідно.

Оцінимо величину $\alpha_{serialP}$ як відношення кількості операцій, що виконуються послідовно на головному процесі в запропонованому методі $N_{serialP}$, до загальної кількості процесів $N_{serialP} + N_{paralP}$.

Як видно з рис. 3.3, у запропонованому методі послідовно виконуються етапи ініціалізації (зчитування навчальної вибірки $S = \langle P, T \rangle$), об'єднання оцінок інформативності V_m й інтервалів розбиття Δp_{nm} ознак p_m , а також формування підсумкової бази правил $RB = RB_{DT} \cup RB_{AR} \cup RB_{NS}$. На етапі об'єднання оцінок індивідуальних інформативностей V_m ознак на головному процесі виконується виключення з загального набору P тих з них, значення оцінок V_m яких нижче мінімально припустимого $V_m < V_{threshold}$. Крім того, як відзначено вище, при формуванні бази правил RB відбувається виключення

надлишкових правил RB_i . Тому часова складність даних процесів лінійно залежить від кількості ознак M і кількості екземплярів Q у вибірці $S = \langle P, T \rangle$ і може бути оцінена як $O(MQ)$. Виходячи з вищесказаного, будемо вважати, що кількість операцій, які виконуються послідовно в запропонованому методі $N_{serialP}$, є пропорційною до величини $O(MQ)$: $N_{serialP} \sim O(MQ)$.

Запропонована модель паралельного процесу видобування продукційних правил (рис. 3.3) передбачає, що паралельно виконується попередня обробка даних (оцінювання значущості V_m ознак p_m стосовно вихідного параметра T і розбиття діапазонів значень ознак p_m на інтервали Δp_{nm}), а також процеси видобування продукційних правил на основі дерев розв'язків $RB_{DT} = DT(S, V_m)$, асоціативних правил $RB_{AR} = AR(S, \Delta p_{nm})$ і негативного відбору $RB_{NS} = NS(S, V_m)$.

Етап попередньої обробки даних, що передбачає обчислення оцінок V_m і розбиття діапазонів значень ознак p_m на інтервали Δp_{nm} , пов'язаний з необхідністю обробки кожного значення p_{qm} кожної ознаки p_m ($m = 1, 2, \dots, M$, $q = 1, 2, \dots, Q$). Тому часова складність даного етапу може бути оцінена як $O(MQ)$.

Найбільш ресурсномістким етапом стохастичного пошуку при видобуванні продукційних правил на основі дерев розв'язків і асоціативних правил є оцінювання розпізнавальних здібностей кожного рішення, що вимагає обробки навчальної вибірки $S = \langle P, T \rangle$. При цьому важливо врахувати, що на кожній з N_{iter} ітерацій пошуку відбувається оцінювання N_χ рішень. Отже, часову складність цього процесу можна визначити в такий спосіб: $O(N_\chi MQ N_{iter})$.

При видобуванні правил на основі негативного відбору процес побудови множини детекторів передбачає необхідність оцінювання кожного кандидата в детектори Ab_k , обробляючи при цьому вибірку $S = \langle P, T \rangle$. У випадку

неможливості включення кандидата Ab_k в список детекторів AB , виконується етап донавчання детектора і повторного його оцінювання. Тому складність даного етапу визначимо за формулою: $O(MQ^2 N_{Ab\max})$, де $N_{Ab\max}$ – максимально припустима кількість детекторів.

З огляду на вищевідзначене, кількість операцій, що виконуються паралельно в запропонованому методі N_{paralP} , визначимо пропорційно величині: $N_{\text{paralP}} \sim O(MQ) + O(N_\chi MQ N_{\text{iter}}) + O(MQ^2 N_{Ab\max})$.

Таким чином, величина α_{serialP} може бути визначена за формулою (3.13):

$$\alpha_{\text{serialP}} = \frac{N_{\text{serialP}}}{N_{\text{serialP}} + N_{\text{paralP}}} = \frac{O(MQ)}{O(MQ) + O(N_\chi MQ N_{\text{iter}}) + O(MQ^2 N_{Ab\max})}. \quad (3.13)$$

Для визначення величин $\alpha_{\text{serialDT}}, \alpha_{\text{serialAR}}, \alpha_{\text{serialNS}}$ оцінимо кількість операцій, що виконуються послідовно ($N_{\text{serialDT}}, N_{\text{serialAR}}, N_{\text{serialNS}}$) і паралельно ($N_{\text{paralDT}}, N_{\text{paralAR}}, N_{\text{paralNS}}$) при видобуванні правил за допомогою процесів $RB_{DT} = DT(S, V_m)$, $RB_{AR} = AR(S, \Delta p_{nm})$ і $RB_{NS} = NS(S, V_m)$. (дис. рис. 3.3).

При видобуванні продукційних правил за допомогою методу на основі дерев розв'язків $RB_{DT} = DT(S, V_m)$ послідовно виконуються операції, пов'язані з перевіркою критеріїв зупинення, відбором рішень і формуванням бази правил RB_{DT} .

Процеси перевірки критеріїв зупинення і відбору рішень передбачають обробку кожного з N_χ рішень на кожній з N_{iter} ітерацій стохастичного пошуку. Тому обчислювальну складність даного процесу оцінимо величиною $O(N_\chi N_{\text{iter}})$. Набір продукційних правил RB_{DT} створюється на основі найбільш прийняттого рішення $\chi_{\text{opt}} : G(\chi_{\text{opt}}) = \min_{k=1,2,\dots,N_\chi} \{G(\chi_k)\}$. При цьому необхідно пройти всі можливі шляхи від кореня дерева до його листів (кінцевих вузлів

дерева). Складність даної процедури не перевищує $O(MQ)$ елементарних операцій. Отже, $N_{serialDT} \sim O(N_\chi N_{iter}) + O(MQ)$.

У паралельному режимі виконуються ресурсномісткі операції, пов'язані з ініціалізацією (створенням множини, що складаються з N_χ рішень), обчисленням значень множини цільових функцій $G = G(\chi_k)$ і формуванням нових множин рішень $\chi_k^{(i+1)}$ на кожній з N_{iter} ітерацій за допомогою операторів схрещування і мутації. Дані операції передбачають необхідність обробки навчальної вибірки $S = \langle P, T \rangle$ (складається з Q екземплярів, кожний з яких описується M ознаками) при оцінюванні кожного з N_χ рішень на кожній з N_{iter} ітерацій стохастичного пошуку. Тому, часову складність паралельних операцій процесу $RB_{DT} = DT(S, V_m)$ можна визначити в такий спосіб: $O(N_\chi MQN_{iter})$.

Виходячи з вищесказаного, величину $\alpha_{serialDT}$ визначимо за формулою (3.14):

$$\alpha_{serialDT} = \frac{N_{serialDT}}{N_{serialDT} + N_{paralDT}} = \frac{O(N_\chi N_{iter}) + O(MQ)}{O(N_\chi N_{iter}) + O(MQ) + O(N_\chi MQN_{iter})}. \quad (3.14)$$

Вище відзначено, що стохастичний процес $RB_{AR} = AR(S, \Delta p_{nm})$ аналогічний процесу $RB_{AR} = AR(S, \Delta p_{nm})$. Отже $\alpha_{serialAR}$ визначимо в такий спосіб (3.15):

$$\alpha_{serialAR} = \alpha_{serialDT} = \frac{O(N_\chi N_{iter}) + O(MQ)}{O(N_\chi N_{iter}) + O(MQ) + O(N_\chi MQN_{iter})}. \quad (3.15)$$

При видобуванні продукційних правил за допомогою негативного відбору $RB_{NS} = NS(S, V_m)$ послідовно виконуються етапи об'єднання множини

детекторів і формування на їх основі бази правил RB_{NS} (рис. 3.2), на що буде потрібно не більш $O(MQ)$ елементарних операцій. Тому $N_{serialNS} \sim O(MQ)$.

Процес побудови множини детекторів є ресурсномістким і виконується на паралельних вузлах обчислювальної системи. Як відзначено вище, обчислювальна складність такого процесу складає $O(MQ^2 N_{Abmax})$. Отже, $N_{paralNS} \sim O(MQ^2 N_{Abmax})$.

У такий спосіб одержуємо вираз (3.16):

$$\alpha_{serialNS} = \frac{N_{serialNS}}{N_{serialNS} + N_{paralNS}} = \frac{O(MQ)}{O(MQ) + O(MQ^2 N_{Abmax})}. \quad (3.16)$$

Підставляючи (3.13) – (3.16) у (3.12), одержуємо частку послідовних операцій запропонованого паралельного методу α_{serial} (3.17):

$$\begin{aligned} \alpha_{serial} = & \frac{O(MQ)}{O(MQ) + O(N_{\chi} MQ N_{iter}) + O(MQ^2 N_{Abmax})} + \\ & + \frac{O(N_{\chi} N_{iter}) + O(MQ)}{O(N_{\chi} N_{iter}) + O(MQ) + O(N_{\chi} MQ N_{iter})} + \\ & + \frac{O(N_{\chi} N_{iter}) + O(MQ)}{O(N_{\chi} N_{iter}) + O(MQ) + O(N_{\chi} MQ N_{iter})} + \frac{O(MQ)}{O(MQ) + O(MQ^2 N_{Abmax})}. \end{aligned} \quad (3.17)$$

Будемо вважати, що в запропонованому паралельному методі при стохастичному пошуку обробляється $N_{\chi} \sim 10^2$ рішень протягом не більш, ніж $N_{iter} \sim 10^2$ ітерацій ($N_{\chi} N_{iter} \sim 10^4$), а максимально припустима кількість детекторів при негативному відборі складає $N_{Abmax} \sim 10^2$. Підставляючи порядки відповідних величин у виразу (3.17), одержуємо залежність (3.18)

оцінки частки послідовних обчислень α_{serial} від кількості екземплярів Q та ознак M у вибірці $S = \langle P, T \rangle$:

$$\alpha_{serial} \sim \frac{O(MQ)}{O(MQ)+10^4 O(MQ)+10^2 O(MQ^2)} + 2 \frac{10^4 + O(MQ)}{10^4 + O(MQ)+10^4 O(MQ)} + \frac{O(MQ)}{O(MQ)+10^2 O(MQ^2)} \sim \frac{1}{10^4 + 10^2 O(Q)} + \frac{2}{O(MQ)} + \frac{2O(MQ)}{10^4 + 10^4 O(MQ)} + \frac{1}{10^4 O(Q)}. \quad (3.18)$$

Чисельно оцінимо величину α_{serial} при обробці великих вибірок даних, що містять $Q \sim 10^4$ екземплярів, описуваних $M \sim 10^4$ ознаками. Підставляючи порядки величин Q й M у формулу (3.18) одержуємо вираз (3.19):

$$\alpha_{serial} \sim \frac{1}{10^4 + 10^2 10^4} + \frac{2}{10^8} + \frac{2 \cdot 10^8}{10^4 + 10^4 10^8} + \frac{1}{10^4 10^4} \approx 2 \cdot 10^{-4}. \quad (3.19)$$

Частка паралельних обчислень складе $\alpha_{paral} = 1 - \alpha_{serial} \approx 1 - 2 \cdot 10^{-4} = 0,9998$, що свідчить про високий ступінь паралелізації в запропонованому методі. Однак відзначимо, що закон Амдала [136–139] не враховує накладні комунікаційні витрати, пов'язані з передачею даних між процесами паралельної системи, тому на практиці значення α_{serial} буде істотно вище.

Визначимо значення максимально можливого прискорення й ефективності обчислювального процесу в паралельній системі шляхом підстановки (3.19) у (3.10) та (3.11):

$$Speedup_{pr} = \frac{1}{2 \cdot 10^{-4} + \frac{1 - 2 \cdot 10^{-4}}{N_{pr}}} = \frac{N_{pr}}{2 \cdot 10^{-4} N_{pr} + 0,9998}, \quad (3.20)$$

$$Efficiency_{pr} = \frac{1}{N_{pr}} \frac{N_{pr}}{2 \cdot 10^{-4} N_{pr} + 0,9998} = \frac{1}{2 \cdot 10^{-4} N_{pr} + 0,9998}. \quad (3.21)$$

При $N_{pr} = 4$ значення максимально можливого прискорення й ефективності складуть: $Speedup_4 = 3,9976$, $Efficiency_4 = 0,9994$; при $N_{pr} = 16$: $Speedup_{16} = 15,95$, $Efficiency_{16} = 0,997$. Отримані значення прискорення, близькі до кількості процесів N_{pr} , і значення ефективності, співрозмірні з одиницею, свідчать про високу ефективність запропонованого паралельного методу видобування продукційних правил.

Важливо відзначити, що оцінки α_{serial} , α_{paral} , $Speedup_{pr}$ та $Efficiency_{pr}$ є теоретичними і не враховують накладні витрати, які залежать від архітектури апаратної частини паралельної системи. На практиці в результаті пересилань даних між процесами та синхронізації роботи процесів реальне прискорення, ефективності й частка паралельних обчислень будуть нижчими.

Запропоновано метод видобування продукційних правил на основі паралельної побудови інтелектуальних моделей, що узагальнюють задані вибірки даних у виді моделей на основі дерев розв'язків, асоціативних правил, негативного відбору. Запропонований підхід дозволяє істотно скоротити часові витрати на синтез моделей при вирішенні складних практичних задач, що характеризуються великими обсягами діагностичних даних, а також задач, де виникає необхідність у модифікації вже існуючих діагностичних і розпізнавальних моделей у зв'язку з обновлюваною інформацією в результаті безупинного спостереження за станом досліджуваних об'єктів або процесів. При цьому забезпечується можливість синтезу моделей з високими апроксимаційними й узагальнювальними властивостями.

3.3 Планування ресурсів паралельної обчислювальної системи при видобуванні продукційних правил

У другому розділі запропоновано методи видобування продукційних правил на основі дерев розв'язків [274], наборів асоціацій [282] і негативного відбору [285]. Недоліком таких методів є їх послідовна реалізація, що ускладнює їх застосування при розв'язанні практичних задач великої розмірності. Для усунення зазначеного недоліку в цьому розділі (п. 3.1) розроблено паралельний метод видобування продукційних правил на основі інтелектуальних обчислень, що використовує як базис запропоновані в [274, 282, 285] методи та передбачає паралелізацію найбільш ресурсномістких операцій зазначених методів. Очевидно, використання цього методу на практиці вимагає великих витрат часових і обчислювальних ресурсів, що обумовлює необхідність застосування паралельних комп'ютерних систем [136–139]. Однак використання ресурсів високопродуктивних систем для паралельних обчислень на кластерах CPU і графічних процесорах (GPU) є досить дорогим і не доступним для великої кількості користувачів [149–163]. Тому для ефективного застосування паралельних комп'ютерних систем і розподілу їх ресурсів серед множини користувачів виконують попереднє планування ресурсів.

Отже, для практичного застосування запропонованого в п.3.1 методу видобування продукційних правил на основі інтелектуальних обчислень необхідно розробити математичне забезпечення для оцінювання обсягу використаних ресурсів паралельної комп'ютерної системи. У цьому підрозділі виконується побудова моделі оцінювання ресурсів паралельних комп'ютерних систем [289], що здійснюють розв'язання прикладних задач на основі паралельного методу видобування продукційних правил.

При оцінюванні обсягу використовуваних ресурсів паралельної системи важливими характеристиками, від яких залежить ефективність застосування системи (швидкість одержання результату t і обсяг використовуваної оперативної пам'яті Mem), є такі групи параметрів: технічні характеристики паралельної системи, параметри використовуваного програмного (математичного) забезпечення, характеристики розв'язуваної прикладної задачі [136–139].

Основними технічними характеристиками паралельної системи, що впливають на час розв'язання практичної задачі і на обсяг використовуваної оперативної пам'яті, будемо вважати:

- x_1 – тип системи $type$ (кластер CPU чи GPU);
- x_2 – кількість процесів, на яких виконується задача N_{pr} (кількість вузлів кластера для CPU або кількість потоків для GPU);
- x_3 – пропускна здатність середовища передачі даних V , Гб/с.

Серед основних параметрів використовуваного математичного забезпечення (у даному випадку, паралельного методу видобування продукційних правил [288]) виділимо такі:

- x_4 – частка вузлів паралельної системи α_{DT} , використовуваних для видобування продукційних правил на основі дерев розв'язків [274];
- x_5 – частка вузлів паралельної системи α_{AR} , використовуваних для видобування знань на основі асоціативних правил [282];
- x_6 – частка вузлів паралельної системи α_{NS} , використовуваних для видобування продукційних правил на основі негативного відбору [285].

Як параметри прикладної задачі, що істотно впливають на обсяг використовуваної пам'яті і на швидкість роботи паралельної системи при виконанні паралельного методу видобування продукційних правил, доцільно використовувати:

- x_7 – кількість спостережень Q у заданій множині спостережень S ;

– x_8 – кількість ознак M у множині спостережень S .

Таким чином, для оцінювання обсягу використовуваних ресурсів паралельної комп'ютерної системи Vol (часу роботи t і обсягу оперативної пам'яті Mem) при виконанні методу видобування продукційних правил необхідно побудувати модель вигляду (3.22):

$$Vol = \{t, Mem\} = Vol(type, N_{pr}, V, \alpha_{DT}, \alpha_{AR}, \alpha_{NS}, Q, M), \quad (3.22)$$

що дозволяє виконувати прогнозування витраченого на виконання паралельного методу видобування продукційних правил часу, а також обсягу оперативної пам'яті в залежності від характеристик системи, параметрів математичного забезпечення й особливостей розв'язуваної прикладної задачі.

Розглянутий метод [289] було застосовано на кластері CPU і на GPU при обробці даних з публічного репозиторію [290], а також при розв'язанні практичних задач [291–293]. Характеристики оброблюваних наборів даних наведено у табл. 3.1.

Таблиця 3.1 – Числові характеристики оброблюваних наборів даних для дослідження паралельного методу видобування продукційних правил

№	Назва задачі	M	Q	Тип ознак	Тип вихідного параметру
1	Розпізнавання автотранспортних засобів [291]	16384	10000	цілі	бінарний
2	Діагностування якості життя хворих на хронічний обструктивний бронхіт від поєднання використовуваних лікарських засобів [292]	95	1023	бінарні	бінарний

Продовження таблиці 3.1

№	Назва задачі	M	Q	Тип ознак	Тип вихідного параметру
3	Діагностування лопаток газотурбінних авіадвигунів за спектрами вільних згасаючих коливань [292]	10240	318	дійсні	бінарний
4	Розпізнавання типів рослин по спектральним точкам [292]	55	248	дійсні	бінарний
5	Побудова моделі якості кондитерських виробів [293]	43	956	дійсні (є дані з пропусками)	дійсний
6	Громади та злочинність [290]	128	1994	дійсні	дійсний
7	Телемоніторинг хвороби Паркінсону [290]	26	5875	дійсні	integer
8	Енергоефективність [290]	8	768	дійсні	дійсний
9	Сила стиснення бетону [290]	9	1030	дійсні	дійсний
10	Лісові пожежі [290]	13	517	дійсні	дійсний

У результаті оброблення даних [290–293] було сформовано навчальну вибірку (3.23), що містить 1032 результати виконання методу, кожний з яких характеризувався вісьма ознаками:

$$D = \langle X, Vol \rangle, \quad (3.23)$$

де $X = \{x_1, x_2, x_3, x_4, x_5, x_6, x_7, x_8\}$, $x_i = \{x_{i1}, x_{i2}, \dots, x_{iN}\}$, $N = 1032$;

$$Vol = \{t, Mem\} = \{\{t_1, t_2, \dots, t_N\}, \{mem_1, mem_2, \dots, mem_N\}\}.$$

У результаті навчальна вибірка являла собою таблицю чисел, що складається з 1032 рядків і десяти стовпців, які містять значення восьми вхідних ознак і двох вихідних (часу роботи системи й обсягу витраченої пам'яті) для кожного випадку застосування розглянутого методу в паралельній системі. Фрагмент навчальної вибірки наведено у табл. 3.2.

Таблиця 3.2 – Фрагмент навчальної вибірки

Значення ознак								<i>Vol</i>	
<i>type</i>	N_{pr}	V	α_{DT}	α_{AR}	α_{NS}	Q	M	T	Mem
0	1	20	0,2	0,3	0,5	318	10240	216,01	25,34
0	10	20	0,2	0,3	0,5	318	10240	40,98	290,67
...
0	3	1	0,25	0,40	0,35	318	10240	107,84	83,48
0	7	1	0,25	0,40	0,35	318	10240	52,38	198,25
...
0	12	20	0,1	0,30	0,6	318	10240	34,15	354,77
0	21	20	0,1	0,30	0,6	318	10240	25,47	521,72
...
1	140	32	0,2	0,3	0,5	318	10240	69,99	27,33
1	240	32	0,2	0,3	0,5	318	10240	40,83	24,85
...
1	60	32	0,27	0,3	0,43	956	43	2,56	0,35
1	180	32	0,27	0,3	0,43	956	43	0,85	0,33
...
0	26	20	0,2	0,3	0,5	1023	95	0,78	22,75
0	32	20	0,2	0,3	0,5	1023	95	0,70	28,47
...

Для виключення впливу різного порядку значень ознак на синтезовану модель виконувалося нормування ознак, тобто приведення діапазону їх значень до єдиного інтервалу $[0;1]$.

Як базис для побудови моделі залежності виду (3.22) використовувалися нейронні мережі прямого поширення, що дозволяють апроксимувати складні нелінійні залежності з високою точністю. Модель (3.22) синтезувалася у вигляді тришарового персептрону [77–80, 90], перший шар якого містив чотири нейрони, другий шар – чотири нейрони, третій шар – два нейрони (по кількості виходів моделі). Усі нейрони мали сигмоїдну функцію активації $\psi(\varphi)$. У якості дискримінантної функції нейронів використовувалася зважена сума [77–80].

Таким чином, структура синтезованої тришарової нейромоделі T_{NN} може бути подана у такий спосіб (3.24):

$$\left\{ \begin{array}{l} Vol = \{ \psi_{(3,1)}(\varphi_{(3,1)}(w_{(3,1)}; \Psi_{(2)})), \psi_{(3,2)}(\varphi_{(3,2)}(w_{(3,2)}; \Psi_{(2)})) \}, Vol = \{ T, Mem \}; \\ \Psi_{(2)} = \{ \psi_{(2,1)}, \psi_{(2,2)}, \psi_{(2,3)}, \psi_{(2,4)} \}; \\ \psi_{(2,k)} = \psi_{(2,k)}(\varphi_{(2,k)}(w_{(2,k)}; \Psi_{(1)})), k = 1, 2, 3, 4; \\ \Psi_{(1)} = \{ \psi_{(1,1)}, \psi_{(1,2)}, \psi_{(1,3)}, \psi_{(1,4)} \}; \\ \psi_{(1,l)} = \psi_{(1,l)}(\varphi_{(1,l)}(w_{(1,l)}; X)), l = 1, 2, 3, 4. \end{array} \right. \quad (3.24)$$

Для побудови нейромоделі та визначення значень її параметрів (вагових коефіцієнтів і зсувів кожного нейрона) на її входи подавалися значення пронормованих ознак, на виходи – значення часу виконання методу синтезу нейро-нечітких мереж у паралельній системі та затрачуваний обсяг оперативної пам'яті. В якості цільової функції при навчанні нейромоделі використовувався мінімум середньоквадратичної помилки E . Прийнятним вважалося досягнення середньоквадратичної помилки порядку 10^{-4} .

Після підстановки отриманих значень вагових коефіцієнтів і зсувів у (3.24) з урахуванням функції активації і дискримінантної функції одержуємо математичний опис синтезованої нейромережевої моделі (3.25), що описує залежності між характеристиками системи, у якій виконується паралельний метод видобування продукційних правил, параметрами досліджуваного методу і часом та обсягом оперативної пам'яті, що витрачаються системою на

видобування правил. Відзначимо, що модель (3.25) описує залежність між вихідними та вхідними параметрами, поданими у нормованому вигляді.

$$\left\{ \begin{array}{l}
 T = \psi_{(3,1)} = \left(1 + e^{-(3,8484 - 0,0145\psi_{(2,1)} - 0,0481\psi_{(2,2)} + 3,9240\psi_{(2,3)} + 0,1388\psi_{(2,4)})} \right)^{-1}; \\
 Mem = \psi_{(3,2)} = \left(1 + e^{-(-0,8644 + 1,2433\psi_{(2,1)} - 1,2925\psi_{(2,2)} - 0,6666\psi_{(2,3)} + 0,3006\psi_{(2,4)})} \right)^{-1}; \\
 \psi_{(2,1)} = \left(1 + e^{-(-1,6567 + 3,0591\psi_{(1,1)} - 0,2137\psi_{(1,2)} + 0,2245\psi_{(1,3)} - 0,1405\psi_{(1,4)})} \right)^{-1}; \\
 \psi_{(2,2)} = \left(1 + e^{-(-4,8177 + 4,9222\psi_{(1,1)} - 1,3346\psi_{(1,2)} + 1,6105\psi_{(1,3)} - 1,5260\psi_{(1,4)})} \right)^{-1}; \\
 \psi_{(2,3)} = \left(1 + e^{-(-0,6787 - 6,9746\psi_{(1,1)} - 0,6947\psi_{(1,2)} + 0,7786\psi_{(1,3)} + 5,1166\psi_{(1,4)})} \right)^{-1}; \\
 \psi_{(2,4)} = \left(1 + e^{-(-2,5299 + 1,0410\psi_{(1,1)} + 0,6746\psi_{(1,2)} + 0,2966\psi_{(1,3)} - 1,4787\psi_{(1,4)})} \right)^{-1}; \\
 \psi_{(1,1)} = \left(1 + e^{-(2,6135 + 0,3796type + 6,4181N_{pr} + 0,0043V + 0,5048\alpha_{DT} + 0,1782\alpha_{AR} + 0,5110\alpha_{NS} - 0,2267Q - 3,2789M)} \right)^{-1}; \\
 \psi_{(1,2)} = \left(1 + e^{-(-0,4403 + -2,1023type - 0,2210N_{pr} + 0,0748V - 0,4068\alpha_{DT} - 2,0229\alpha_{AR} + 2,8968\alpha_{NS} + 0,2301Q - 0,2039M)} \right)^{-1}; \\
 \psi_{(1,3)} = \left(1 + e^{-(-0,3057 + 1,6824type - 0,4436N_{pr} + 0,7853V - 1,0850\alpha_{DT} - 0,3828\alpha_{AR} + 2,6398\alpha_{NS} - 0,0768Q - 0,7402M)} \right)^{-1}; \\
 \psi_{(1,4)} = \left(1 + e^{-(-1,5641 + 2,3682type - 0,9614N_{pr} + 0,0142V - 0,8409\alpha_{DT} - 0,444\alpha_{AR} - 1,0934\alpha_{NS} + 0,2893Q + 2,4426M)} \right)^{-1};
 \end{array} \right. \quad (3.25)$$

Графічну інтерпретацію синтезованої нейромоделі наведено на рис. 3.4. Значення середньоквадратичної помилки синтезованої моделі склало $1,92 \times 10^{-4}$, що є прийнятним для подібного роду задач.

Таким чином, запропоновано модель оцінювання використовуваних ресурсів комп'ютерної системи при виконанні паралельного методу видобування продукційних правил. Побудована нейромережева модель являє собою ієрархічну поліалгоритмічну структуру, яка містить нейроподібні обчислювальні елементи і дозволяє оцінювати ресурси, затрачувані паралельною комп'ютерною системою для видобування продукційних правил при моделюванні складних об'єктів і процесів.




Рисунок 3.4 – Синтезована нейромережева модель

Модель враховує тип комп'ютерної системи, кількість процесів, на яких виконується задача, пропускну здатність мережі передачі даних, параметри використовуваного математичного забезпечення (частку вузлів паралельної системи, використовуваних для видобування продукційних правил на основі дерев розв'язків, частку вузлів паралельної системи, використовуваних для видобування знань на основі асоціативних правил, частку вузлів паралельної системи, використовуваних для видобування продукційних правил на основі негативного відбору), а також параметри розв'язуваної прикладної задачі (кількість спостережень і кількість ознак у заданій множині даних, що описує результати спостережень за досліджуваним об'єктом або процесом). Синтезована нейромережева модель є поліалгоритмічною, дозволяє виконувати оцінювання двох характеристик (часу й обсягу використовуваної пам'яті) паралельної системи при виконанні методу видобування продукційних правил.

3.4 Висновки за розділом 3

Вирішено актуальну задачу автоматизації синтезу продукційних правил на основі паралельних обчислень та обчислювального інтелекту.

Запропоновано паралельний метод видобування продукційних правил на основі обчислювального інтелекту, що передбачає паралельну побудову інтелектуальних моделей, які узагальнюють задані вибірки даних у вигляді моделей на основі дерев розв'язків, асоціативних правил, негативного відбору. Запропонований підхід дозволяє суттєво скоротити часові витрати на синтез моделей при розв'язанні складних практичних задач, що характеризуються великими обсягами діагностичних даних, а також задач, де виникає необхідність у модифікації вже існуючих діагностичних і розпізнавальних моделей у зв'язку з отриманням нової інформації в процесі спостережень за

станом досліджуваних об'єктів або процесів. При цьому забезпечується можливість синтезу моделей з високими апроксимаційними й узагальнювальними властивості.

Дано теоретичні оцінки обчислювальної складності запропонованого паралельного методу видобування продукційних правил, що свідчать про високу ефективність застосування паралельного підходу для індукції правил на основі заданих наборів прецедентів.

Вирішено задачу оцінювання ресурсів комп'ютерної системи при видобуванні продукційних правил. Запропоновано модель оцінювання використовуваних ресурсів комп'ютерної системи при виконанні паралельного методу видобування продукційних правил. Модель враховує тип комп'ютерної системи, кількість процесів, на яких виконується задача, пропускну здатність мережі передачі даних, параметри використовуваного математичного забезпечення (частку вузлів паралельної системи, використовуваних для видобування продукційних правил на основі дерев розв'язків, частку вузлів паралельної системи, використовуваних для видобування знань на основі асоціативних правил, частку вузлів паралельної системи, використовуваних для видобування продукційних правил на основі негативного відбору), а також параметри розв'язуваної прикладної задачі (кількість спостережень і кількість ознак у заданій множині даних, що описує результати спостережень за досліджуваним об'єктом або процесом). Синтезована нейромережева модель є поліалгоритмічною, дозволяє виконувати оцінювання двох характеристик (часу й обсягу використовуваної пам'яті) паралельної системи при виконанні методу видобування продукційних правил.

Список використаних джерел у цьому розділі наведено у повному списку використаних джерел під номерами [45, 57–63, 77–80, 90, 97, 133–141, 149–163, 220–228, 274–293].

4 РЕДУКЦІЯ ВЕЛИКИХ МАСИВІВ ДАНИХ

Як відзначалося у першому розділі, для синтезу інтерпретованих діагностичних моделей доцільною є попередня обробка наявних експериментальних даних, що характеризують досліджувані об'єкти та процеси. У цьому розділі задля спрощення створюваних діагностичних моделей за вибірками даних великої розмірності розроблюються система критеріїв оцінювання інформативності ознак та метод скорочення розмірності даних, що дозволять виявляти неінформативні ознаки та екземпляри навчальної вибірки та виключати їх з подальшого розгляду при синтезі діагностичних моделей, що, у свою чергу, зменшить структурну і параметричну складність отримуваних моделей, скоротить час їх синтезу, підвищить рівні узагальнення та інтерпретованості діагностичних моделей.

4.1 Система критеріїв оцінювання інформативності ознак для синтезу діагностичних моделей

Використання інформаційних критеріїв [50, 62, 131, 195, 199, 200] для редукції даних та оцінювання індивідуальної і групової інформативності ознак (п.1.4.3) на практиці ускладнюється в силу того, що такі критерії передбачають взаємну незалежність ознак вихідної вибірки даних. При цьому реальні вибірки даних, як правило, містять взаємозалежні ознаки, включення яких в діагностичну або розпізнавальну модель погіршує її апроксимаційні й узагальнювальні властивості, підвищує структурну складність моделі, а також погіршує її інтерпретованість. Крім того, можливість використання таких критеріїв на практиці заснована на припущенні про нормальність розподілу образів, що становлять класи вибірки $S = \langle P, T \rangle$.

Тому доцільним є створення системи критеріїв оцінювання інформативності ознак, що дозволяє обчислювати інформативність наборів взаємозалежних ознак.

У розробленій системі критеріїв [313] пропонується оцінювати інформативність ознак виходячи з просторового розташування екземплярів різних класів (діапазонів зміни значень вихідного параметра). На відміну від критеріїв, запропонованих і використовуваних в роботах [199, 200], що дозволяють оцінювати індивідуальну інформативність ознак при класифікації, розроблена система критеріїв дозволяє оцінювати також групову інформативність ознак при вирішенні задач класифікації і регресії.

Введемо визначення індивідуальної та групової інформативності.

Визначення 1. Індивідуальна інформативність $V(p_m)$ ознаки p_m – величина, що характеризує взаємозв'язок ознаки p_m з вихідним параметром T .

Визначення 2. Групова інформативність $V(P^*)$ набору ознак $P^* \subseteq P$ – величина, що характеризує взаємозв'язок набору ознак P^* з вихідним параметром T .

Визначення 3. Часткова індивідуальна інформативність $V(p_{qm})$ ознаки p_m стосовно екземпляра $s_q \in S$ – величина, що характеризує якість розподілу по класах (для неперервних значень вихідного параметра T – якість розподілу по інтервалах розбиття вихідного параметра T) найближчих до s_q екземплярів по осі ознаки p_m .

Визначення 4. Часткова групова інформативність $V(P^*, s_q)$ набору ознак $P^* \subseteq P$ стосовно екземпляра $s_q \in S$ – величина, що характеризує якість розподілу по класах (для неперервних значень вихідного параметра T – якість розподілу по інтервалах розбиття вихідного параметра T) найближчих до s_q екземплярів у просторі ознак P^* .

При оцінюванні індивідуальної і групової інформативності будемо враховувати характеристики навчальної вибірки $S = \langle P, T \rangle$, пов'язані з типом значень вихідного параметра (дискретні з заданою кількістю значень, наприклад, при вирішенні задачі розпізнавання на два чи декілька класів; дійсні значення вихідного параметра), наявність пропущених значень (incomplete data, missed values) у даних вибірки.

Для оцінювання індивідуальної інформативності ознак p_m при вирішенні задач розпізнавання на два класи будемо використовувати критерій $V(p_m)$, що розраховується в такий спосіб. Спочатку з заданої вибірки даних $S = \langle P, T \rangle$ випадковим чином обирається множина екземплярів $S' \subset S$ ($|S'| < |S|$). Потім для кожного екземпляра s_q з множини S' обчислюється часткова індивідуальна інформативність $V(p_{qm})$ для кожної з ознак p_m (4.21):

$$V(p_{qm}) = \Delta p_m(s_q; s_{qoth}) - \Delta p_m(s_q; s_{qsame}), \quad (4.21)$$

де величини $\Delta p_m(s_q; s_{qoth})$ і $\Delta p_m(s_q; s_{qsame})$ розраховуються за формулами (4.22) і (4.23), відповідно:

$$\Delta p_m(s_q; s_{qoth}) = |p_{qm} - p_{qmoth}|, \quad (4.22)$$

$$\Delta p_m(s_q; s_{qsame}) = |p_{qm} - p_{qmsame}|. \quad (4.23)$$

Характеристики p_{qmoth} і p_{qmsame} являють собою значення m -ї ознаки для найближчих до s_q екземплярів з іншим і таким же значенням класів, відповідно: $s_{qoth} = \min_{t_q \neq t_{qoth}} |p_{qm} - p_{qmoth}|$, $s_{qsame} = \min_{t_q = t_{qsame}} |p_{qm} - p_{qmoth}|$. При цьому для визначення значень величин $\Delta p_m(s_q; s_{qoth})$ і $\Delta p_m(s_q; s_{qsame})$ використовуються нормовані значення ознак p_{qm} , що дозволяє привести значення оцінок $V(p_{qm})$ та $V(p_m)$ до легко інтерпретовного інтервалу $[-1; 1]$.

Використання формул (4.21) – (4.23) для визначення часткової індивідуальної інформативності $V(p_{qm})$ засновано на припущенні про те, що інформативність ознаки є тим вищою, чим краще вона розділяє екземпляри вибірки на класи. Виходячи з цього, чим далі від екземпляра s_q класу t_q на осі ознаки p_m знаходиться найближчий до нього екземпляр $s_{qoth} = \min_{t_q \neq t_{qoth}} |p_{qm} - p_{qmoth}|$ іншого класу $t_{qoth} \neq t_q$, тим вищою є часткова індивідуальна інформативність $V(p_{qm})$. Аналогічно, чим далі від екземпляра s_q на осі ознаки p_m знаходиться найближчий до нього екземпляр $s_{qsame} = \min_{t_q = t_{qsame}} |p_{qm} - p_{qmoth}|$ такого ж класу $t_{qsame} = t_q$, тим нижчою є часткова індивідуальна інформативність $V(p_{qm})$.

Після визначення оцінок часткової індивідуальної інформативності $V(p_{qm})$ для всіх ознак p_m всіх екземплярів $s_q \in S' \subset S$ виконується обчислення значень індивідуальної інформативності $V(p_m)$ ознак за формулою (4.24):

$$V(p_m) = \frac{1}{|S'|} \sum_{s_q \in S'} V(p_{qm}). \quad (4.24)$$

Таким чином, ознаки з високими значеннями ($V(p_m) \rightarrow 1$) індивідуальної інформативності $V(p_m)$ вважаються значущими й інформативними стосовно вихідного параметра T , ознаки зі значеннями $V(p_m) \rightarrow -1$ вважаються малозначущими.

У випадку, якщо вихідна вибірка $S = \langle P, T \rangle$ містить інформацію про екземпляри s_q , що характеризуються пропущеними значеннями деяких з ознак p_{qm} , можна використовувати три підходи. При першому підході екземпляри з пропущеними значеннями p_{qm} ознак не враховуються при обчисленні оцінок інформативності ознак $V(p_m)$. Такий підхід є простим у реалізації. Однак при

його використанні втрачається наявна інформація в навчальних вибірках. Крім того, деякі вибірки даних $S = \langle P, T \rangle$ (наприклад, при вирішенні задач медичного діагностування, де можливі випадки відсутності значень деяких з можливих вимірюваних характеристик у більшості пацієнтів) можуть містити переважно більшість екземплярів s_q , значення деяких ознак яких або не вимірювалися взагалі в силу відсутності такої необхідності (наприклад, параметри, що характеризують деяке специфічне захворювання), або вимірювання яких було доволі важким і не проводилося для більшості екземплярів s_q (наприклад, параметри об'єктів технічного діагностування, вимірювання яких вимагає використання спеціальних методів руйнівного контролю якості, у результаті чого вимірюваний виріб стає некондиційним). Використання першого підходу, що припускає виключення з розгляду екземплярів s_q із пропущеними значеннями, може привести до неадекватного оцінювання інформативності ознак, і, як наслідок, до некоректних результатів процедури відбору ознак.

В другому підході, при наявності у вибірці $S = \langle P, T \rangle$ екземплярів s_q із пропущеними значеннями, величини $\Delta p_m(s_q; s_{q\text{oth}})$ і $\Delta p_m(s_q; s_{q\text{same}})$, використовувані при обчисленні оцінок часткової індивідуальної інформативності $V(p_{qm})$, доцільно визначати за формулою (4.25):

$$\Delta p_m(s_q; s_{q\text{os}}) = 1 - \frac{1}{N_{\text{int}}(p_m)}. \quad (4.25)$$

При цьому $s_{q\text{os}}$ являє собою найближчий до s_q екземпляр з іншим чи таким самим значенням вихідного параметра. Формула (4.25) використовується замість формул (4.22) та/або (4.23) у випадку, якщо для одного з екземплярів s_q , $s_{q\text{oth}}$, $s_{q\text{same}}$ не визначено значення p_{qm} ознаки p_m . У формулі (4.25) $N_{\text{int}}(p_m)$ – це кількість різних значень (у випадку, якщо ознака p_m приймає

задану обмежену кількість дискретних значень) або кількість інтервалів розбиття діапазону значень ознаки p_m (у випадку, якщо ознака p_m приймає дійсні значення з заданого інтервалу).

При використанні третього підходу замість формули (4.25) для обчислення величини $\Delta p_m(s_q; s_{qos})$ застосовується оцінка ймовірності того, що екземпляри s_q і s_{qos} (s_{qoth} або s_{qsame}) мають різні значення для заданої ознаки p_m :

– якщо один екземпляр (наприклад, s_q) має невизначене значення p_{qm} , тоді оцінка $\Delta p_m(s_q; s_{qos})$ обчислюється за формулою (4.26):

$$\Delta p_m(s_q; s_{qos}) = 1 - \rho(p_{qos,m} | t_q), \quad (4.26)$$

де ймовірність $\rho(p_{qos,m} | t_q)$ обчислюється на основі даних вибірки $S = \langle P, T \rangle$ за формулою (4.27):

$$\rho(p_{qos,m} | t_q) = \frac{N(s \in S : (p_m = p_{qos,m}) \cap (T = t_q))}{N(t_q)}, \quad (4.27)$$

де $N(s \in S : (p_m = p_{qos,m}) \cap (T = t_q))$ – кількість екземплярів вибірки $S = \langle P, T \rangle$ зі значенням ознаки p_m , що дорівнює $p_{qos,m}$, і значенням вихідного параметра T , що дорівнює t_q ; $N(t_q)$ – кількість екземплярів вибірки S зі значенням вихідного параметра T , що дорівнює t_q ;

– якщо обидва екземпляри s_q і s_{qos} мають невизначене значення ознаки p_m , тоді оцінка $\Delta p_m(s_q; s_{qos})$ визначається за формулою (4.28):

$$\Delta p_m(s_q; s_{qos}) = 1 - \sum_{l=1}^{N_{int}(p_m)} \rho(p_m = p_{lm} | t_q) \cdot \rho(p_m = p_{lm} | t_{qos}). \quad (4.28)$$

Формули (4.26) – (4.28) враховують щільність розподілу значень ознак p_m по екземплярах вибірки $S = \langle P, T \rangle$ і дозволяють при визначенні інформативності ознак $V(p_m)$ враховувати оцінки ймовірностей того, що ознаки p_m приймуть визначені значення p_{lm} .

При необхідності відбору інформативних ознак для розв'язання завдань діагностування при множині класів (вихідний параметр T може приймати різні значення t_q з множини T' , $|T'| > 2$) оцінки інформативності ознак $V(p_m)$ можуть бути розраховані за формулами (4.21) – (4.28). При цьому як екземпляр s_{qoth} приймається екземпляр, мінімально віддалений від екземпляра s_q по осі оцінюваної ознаки p_m з іншим значенням класу T : $s_{qoth} = \min_{t_q \neq t_{qoth}} |p_{qm} - p_{qm_{oth}}|$.

Також у випадку розпізнавання на множині класів ($|T'| > 2$) можна враховувати відстань не тільки до найближчого до s_q екземпляра з протилежним значенням класу T , а середню відстань до множини S'_q найближчих екземплярів кожного з можливих класів $t_l \in T'$, $t_l \neq t_q$. У такому випадку для оцінювання часткової індивідуальної інформативності $V(p_{qm})$ ознаки p_m необхідно розрахувати величину (4.29), що являє собою середню відстань між екземпляром s_q і найближчими до нього екземплярами з протилежними класами, зважену на частоту класів вибірки $S = \langle P, T \rangle$:

$$\Delta p_m(s_q; S'_q) = \sum_{\substack{l=1 \\ t_l \neq t_q}}^{|T'|} \rho(t_l) \cdot \Delta p_m(s_q; s_l). \quad (4.29)$$

У формулі (4.29) величина $\Delta p_m(s_q; s_l)$ визначає відстань по осі ознаки p_m між екземпляром s_q і найближчим до нього екземпляром $s_l \in S'_q$ зі значенням вихідного параметра $t_l \in T'$, $t_l \neq t_q$; $\rho(t_l)$ – імовірність того, що

екземпляри вибірки $S = \langle P, T \rangle$ характеризуються класом t_l , визначається як відношення кількості екземплярів вибірки $N(t_l)$ з класом t_l до загальної кількості екземплярів Q вибірки S .

Тоді часткова індивідуальна інформативність $V(p_{qm})$ ознаки p_m може бути обчислена за формулою (4.30):

$$V(p_{qm}) = \Delta p_m(s_q; S'_q) - \Delta p_m(s_q; s_{q\text{same}}), \quad (4.30)$$

а індивідуальна інформативність $V(p_{qm})$ ознаки p_m визначається за формулою (4.24).

Для оцінювання групової інформативності набору ознак $P^* \subseteq P$ на основі даних вибірки $S = \langle P, T \rangle$ пропонується використовувати критерій $V(P^*)$, що розраховується в такий спосіб [313, 314]. З метою скорочення обчислювальних операцій на початковому етапі випадковим чином із заданої вибірки даних $S = \langle P, T \rangle$ вибирається множина екземплярів $S' \subset S$ ($|S'| < |S|$). Після цього для кожного екземпляра $s_q \in S'$ обчислюється часткова групова інформативність $V(P^*, s_q)$ для оцінюваного набору ознак $P^* \subseteq P$ (4.31):

$$V(P^*, s_q) = \Delta P^*(s_q; s_{q\text{oth}}) - \Delta P^*(s_q; s_{q\text{same}}), \quad (4.31)$$

де величини $\Delta P^*(s_q; s_{q\text{oth}})$ і $\Delta P^*(s_q; s_{q\text{same}})$ визначають відстань у просторі ознак P^* між екземпляром s_q і найближчими до нього екземплярами $s_{q\text{oth}}$ і $s_{q\text{same}}$ з іншим і таким же значенням класів, відповідно. Відстані $\Delta P^*(s_q; s_{q\text{os}})$ між екземплярами s_q і $s_{q\text{os}}$ ($s_{q\text{oth}}$ або $s_{q\text{same}}$) можна визначати за формулами (4.32) – (4.34), що являють собою метрики для обчислення відстаней Евкліду, Хеммінгу

та Мінковського, відповідно [131, 132, 195] (при цьому ω – параметр, що задається користувачем):

$$\Delta P^*(s_q; s_{qos}) = \sqrt{\sum_{p_m \in P^*} (p_{qm} - p_{qos,m})^2}, \quad (4.32)$$

$$\Delta P^*(s_q; s_{qos}) = \sum_{p_m \in P^*} |p_{qm} - p_{qos,m}|, \quad (4.33)$$

$$\Delta P^*(s_q; s_{qos}) = \sqrt[\omega]{\sum_{p_m \in P^*} |p_{qm} - p_{qos,m}|^\omega}. \quad (4.34)$$

Для визначення значень величин $\Delta P^*(s_q; s_{qos})$ використовуються нормовані значення ознак p_{qm} . Групова інформативність $V(P^*)$ набору ознак $P^* \subseteq P$ визначається як середнє значення суми часткових інформативностей $V(P^*, s_q)$: $V(P^*) = \frac{1}{|S'|} \sum_{s_q \in S'} V(P^*, s_q)$. У випадку, якщо деякі екземпляри s_q містять пропущені значення ознак p_{qm} , то величини $\Delta P^*(s_q; s_{qos})$ можуть оцінюватися за аналогією з виразами (4.25) – (4.28), використовуваними при оцінюванні індивідуальної інформативності ознак.

При відборі інформативних ознак у задачах регресії (вихідний параметр T може приймати різні значення t_q з діапазону значень $|T'| \in [t_{\min}; t_{\max}]$) для оцінювання індивідуальної $V(p_m)$ і групової $V(P^*)$ інформативності ознак пропонується використовувати вирази, наведені вище. При цьому вихідний діапазон значень $|T'| \in [t_{\min}; t_{\max}]$ вихідного параметра T необхідно розбити на $N_{\text{int}}(T)$ інтервалів. Потім на основі формул (4.21) – (4.34) обчислити оцінки $V(p_m)$ або $V(P^*)$.

Важливим є питання вибору кількості інтервалів $N_{\text{int}}(T)$, на які розбивається вихідний діапазон $|T'| \in [t_{\text{min}}; t_{\text{max}}]$ значень вихідного параметра T . У випадку, якщо експертом у прикладній задачі, чисельні дані якої представлені у вигляді вибірки $S = \langle P, T \rangle$, заданий прийнятний рівень точності ε_n , то кількість інтервалів $N_{\text{int}}(T)$ може бути визначена за формулою (4.35):

$$N_{\text{int}}(T) = \text{ceil}\left(\frac{1}{2\varepsilon_n}\right). \quad (4.35)$$

Використання наведеної вище формули дозволить розбивати діапазон значень вихідного параметра T таким чином, щоб нормалізована ширина кожного інтервалу ΔT його розбиття не перевищувала величини ε_n : $\Delta T \leq \varepsilon_n$. При цьому при побудові діагностичних чи розпізнавальних моделей, а також при оцінюванні інформативності ознак, значення вихідного параметра t_q оцінюваного екземпляра s_q відображається на інтервал $\Delta t_l : t_q \in [\Delta t_{l\text{min}}; \Delta t_{l\text{max}}]$.

Таким чином, запропонована система критеріїв оцінювання інформативності ознак передбачає визначення значущості ознак виходячи з просторового розташування екземплярів різних класів (діапазонів зміни значень вихідного параметра). Розроблена система критеріїв дозволяє оцінювати індивідуальну та групову інформативність ознак при розв'язанні задач класифікації та регресії в умовах, коли вихідні вибірки даних містять надлишкові і взаємозалежні ознаки, а також екземпляри з пропущеними значеннями. Запропоновані критерії не вимагають побудови моделей на основі оцінюваних комбінацій ознак, що істотно знижує часові й обчислювальні витрати в процесі відбору інформативних ознак. Використання запропонованих критеріїв для оцінювання та відбору інформативних ознак дозволяє при розв'язанні задач діагностування і розпізнавання образів знижувати структурну

складність синтезованих діагностичних і розпізнавальних моделей, підвищувати їх інтепретовність (розуміння людиною) і узагальнювальні властивості за рахунок виключення малозначущих, взаємозалежних і надлишкових ознак.

4.2 Паралельний стохастичний метод редукції даних

Як зазначено вище, застосування відомих методів відбору ознак на практиці при обробці великих даних є складним в силу високої ітеративності і великого обсягу обчислень [126–132, 195–203]. Крім того, використовувані стратегії пошуку при відборі ознак також є недостатньо ефективними при дослідженні різних областей простору пошуку. Так, жадібна стратегія, яка використовується в евристичних методах відбору ознак [131, 132, 195], дозволяє досліджувати дуже малу частину простору пошуку, оскільки в такому випадку застосовується чітко задана, детермінована послідовність дій, що передбачає дуже обмежений аналіз простору ознак (в процесі оптимізації цільового критерію $V(P^*)$ досліджується мала кількість пробних точок). Метод повного перебору також використовує чітко визначену послідовність дій, яка передбачає дослідження всіх точок простору пошуку, що через істотні часові витрати унеможлиблює його використання за значного числа ознак M у вхідній множині $S = \langle P, T \rangle$.

У стохастичних методах (еволюційні, мультиагентні тощо [57–63, 204–216, 294]) використовуються стратегії, засновані на імовірнісному пошуку і перевірці випадково вибраних точок X_e простору пошуку XS . Це дозволяє досліджувати більшу частину пошукового простору в порівнянні з детермінованими методами. Однак методи, які використовують стохастичні стратегії, схильні до зациклення в областях локальних екстремумів (в разі

знаходження на деякій ітерації областей локальних оптимумів спостерігається подальше зосередження рішень навколо таких областей). Не дивлячись на наявність механізмів виходу з локальних екстремумів (наприклад, використання оператора мутації в методах еволюційного пошуку або процедури перезапуску агентів у агентно-орієнтованих методах обчислювального інтелекту) концентрування деякого числа рішень (пробних точок) навколо областей локальних екстремумів тим не менш спостерігається і на наступних ітераціях пошуку. Це знижує ефективність пошуку (досліджуються одні і ті ж області простору ознак), збільшує час його виконання на обчислювальній машині, і, в деяких випадках, не дозволяє знайти прийнятне рішення.

Тому для усунення зазначених недоліків в розробленому паралельному стохастичному методі редукції даних [315] пропонується використовувати поєднання різних стратегій стохастичного пошуку (методи, засновані на еволюційному і мультиагентному підходах [59, 294, 316]), що реалізуються на різних вузлах паралельної системи. Використання різних стратегій, заснованих на ймовірнісному підході, дозволить у порівнянні з існуючими методами [57–63, 126–132, 195–216, 294] істотно розширити покриття простору пошуку. Застосування паралельних обчислень дозволить скоротити час пошуку, і, як наслідок, збільшити практичний поріг застосування методів відбору ознак при обробці великих масивів даних.

У запропонованому паралельному методі редукції великих даних на етапі ініціалізації на головному ядрі Pr_0 відбувається запуск процесу редукції даних, зчитується вхідна інформація від користувача (вибірка даних $S = \langle P, T \rangle$, параметри методу тощо).

Потім по ядрах $Pr_1, Pr_2, \dots, Pr_{NPr-1}$ обчислювальної системи розподіляються методи відбору ознак, а також передається доступ до вхідної вибірки $S = \langle P, T \rangle$. При цьому пропонується [317–325] на низькоітеративні методи (на основі дерев рішень і на основі асоціативних правил) виділяти по

одному ядру: Pr_{NPr-2}, Pr_{NPr-1} , відповідно. Серед інших ядер $Pr_1, Pr_2, \dots, Pr_{NPr-3}$ рівномірно розподіляються більш складні методи редукції даних, що використовують в якості базису еволюційний і мультиагентний підходи. Так, наприклад, для 24-х ядерної системи розподіл методів відбору ознак по ядрах обчислювальної системи може бути наступним: Pr_0 – головний процес, $Pr_1 - Pr_6$ – відбір ознак на основі еволюційного пошуку з групуванням ознак [294], $Pr_7 - Pr_{11}$ – відбір ознак на основі еволюційного пошуку з кластеризацією ознак [294], $Pr_{12} - Pr_{16}$ – відбір ознак на основі мультиагентного пошуку з прямим зв'язком між агентами [294], $Pr_{17} - Pr_{21}$ – відбір ознак на основі мультиагентного пошуку з непрямим зв'язком між агентами [294, 310], Pr_{22} – відбір ознак на основі дерев рішень [294], Pr_{23} – відбір ознак на основі асоціативних правил [293].

Після цього на кожному ядрі $Pr_1, Pr_2, \dots, Pr_{NPr-1}$ виконується процес скорочення ознак вибірки $S = \langle P, T \rangle$. Для підвищення рівномірності покриття простору пошуку в процесі відбору ознак на різних вузлах паралельної системи використовуються різні методи стохастичного пошуку. В якості таких методів пропонується використовувати наступні:

- еволюційний пошук з групуванням ознак [294] – заснований на використанні апріорної інформації про значущість ознак в процесі відбору ознак. В якості апріорної інформації в процесі пошуку в еволюційних операторах схрещування і мутації використовуються оцінки $V(p_m)$ індивідуальної інформативності ознак p_m , що обчислюються на етапі ініціалізації методу;

- еволюційний метод з кластеризацією ознак [294] – аналогічно попередньому методу в процесі еволюційної оптимізації використовує оцінки $V(p_m)$ індивідуальної інформативності ознак p_m . Крім оцінок $V(p_m)$ також використовується інформація про розташування ознак p_m у просторі екземплярів, що дозволяє групувати їх в процесі пошуку і формувати

контрольні точки Xe_k з ознак, віддалених одна від одної в просторі екземплярів, виключаючи тим самим з розгляду комбінації взаємозалежних ознак;

– мультиагентний метод з прямим зв'язком між агентами [294] – заснований на застосуванні агентних технологій обчислювального інтелекту, не використовує процедур евристичного пошуку, застосовує агентний підхід до обміну інформацією, що дозволяє більш детально дослідити області простору пошуку з перспективними контрольними точками. Даний метод ефективно може використовуватися для відбору ознак при синтезі моделей класифікації (за дискретних значень вихідного параметра);

– мультиагентний метод з непрямим зв'язком між агентами [294, 310] – використовує еволюційні оператори схрещування і мутації на етапі відтворення агентів, що дозволяє більш ефективно досліджувати простір пошуку в порівнянні з відомими мультиагентними методами і скоротити час пошуку. Такий метод дозволяє в умовах взаємної залежності ознак виконувати виділення найбільш значущої комбінації ознак, не схильний до зациклення в локальних оптимумах, не використовує жадібну стратегію пошуку і не висуває додаткові вимоги до виду цільової функції;

– метод відбору ознак на основі дерев рішень [294] – оцінювання інформативності наборів ознак Xe_k виконується на основі синтезованих в процесі пошуку дерев рішень. Метод дозволяє оцінювати як індивідуальну, так і групову інформативність ознак p_m навчальної вибірки $S = \langle P, T \rangle$ шляхом використання структури синтезованого дерева, передбачає виконання етапів додавання корневих ознак і утинання дерева. Такий метод не є високоітеративним і не вимагає значних обчислювальних ресурсів, що дозволяє його застосовувати для пошуку комбінації найбільш значущих ознак в умовах обмеження часових і обчислювальних ресурсів, а при використанні паралельних систем – задіяти невелике число вузлів Pr_j ;

– метод відбору ознак на основі асоціативних правил [293] – може ефективно використовуватися для відбору інформативних ознак з вибірок даних $S = \langle P, T \rangle$, сформованих на основі транзакційних наборів даних $D = \{T_1, T_2, \dots, T_{N_D}\}$, в яких кожен елемент (транзакція) T_j , $j = 1, 2, \dots, N_D$ містить інформацію про деякі взаємопов’язані події, об’єкти або процеси. При цьому транзакції T_j набору даних D являють собою перелік з деякої множини елементів. Для оцінювання інформативності $V(p_m)$ ознак у методі відбору ознак на основі асоціативних правил [293] використовується інформація про особливості витягнутих наборів асоціацій (асоціативних правил).

Під час відбору ознак у запропонованому паралельному методі редукції великих даних процеси $Pr_1, Pr_2, \dots, Pr_{N_{Pr}-1}$ можуть обмінюватися сигналами з головним процесом Pr_0 . При цьому з процесів $Pr_1, Pr_2, \dots, Pr_{N_{Pr}-1}$ на головний процес Pr_0 надходить сигнал Sgn_{inj} про завершення відбору ознак на j -му процесі Pr_j при досягненні деякого з заданих критеріїв зупинки. В якості таких критеріїв можуть використовуватися:

– $Crit_1$ – успішне знаходження комбінації ознак P^* , що задовольняє заданим мінімально прийнятним умовам пошуку (наприклад: $V(P^*) \leq V_{\min}$, де V_{\min} – мінімально прийнятне значення критерію оптимальності набору ознак, задане користувачем на етапі ініціалізації);

– $Crit_2$ – максимально прийнятна кількість ітерацій пошуку;

– $Crit_3$ – максимально прийнятна кількість обчислень значень цільової функції.

В якості критеріїв зупинки можуть використовуватися й інші критерії.

З головного процесу Pr_0 на процеси $Pr_1, Pr_2, \dots, Pr_{N_{Pr}-1}$ надходять сигнали Sgn_{outj} про необхідність завершення процедури відбору ознак на конкретному процесі Pr_j . Сигнали Sgn_{outj} можуть подаватися головним процесом у таких випадках:

– при отриманні від будь-якого процесу $Pr_1, Pr_2, \dots, Pr_{NPr-1}$ сигналу Sgn_{inj} про успішне завершення пошуку при задоволенні критерію $Crit_1$. У такому випадку подальший пошук на інших процесах втрачає сенс, оскільки прийнятне рішення вже знайдено на процесі Pr_j ;

– при отриманні від деякої множини процесів $Pr_1, Pr_2, \dots, Pr_{NPr-1}$ (наприклад, не менше, ніж від половини процесів $Pr_1, Pr_2, \dots, Pr_{NPr-1}$) сигналу Sgn_{inj} про завершення пошуку при задоволенні критеріїв $Crit_2$ або $Crit_3$. У такому випадку продовження процедури відбору ознак на процесах, що залишилися, вважається недоцільним в силу простою більшої частини наявних ядер обчислювальної системи, і виконується передача поточної інформації з процесів $Pr_1, Pr_2, \dots, Pr_{NPr-1}$ на процес Pr_0 ;

– при досягненні максимально допустимого часу пошуку $Crit_4$, після якого на кожному процесі $Pr_1, Pr_2, \dots, Pr_{NPr-1}$ виконується завершення поточної ітерації пошуку і передача інформації на головний процес про множину досліджених контрольних точок $Xe \in XS$ і відповідні їм значення цільової функції $V(Xe)$.

У процесі пошуку зберігається інформація $Inf_k = \langle Xe_k, V(Xe_k) \rangle$ про досліджені на кожному ядрі $Pr_1, Pr_2, \dots, Pr_{NPr-1}$ точки $Xe \in XS$ простору пошуку XS . Це дозволяє оцінювати просторове розташування рішень, а також їх переміщення в процесі пошуку. Крім того, такий підхід дозволяє не виконувати повторне оцінювання (обчислення значень цільової функції $V(Xe)$) рішень $Xe \in XS$, оцінених раніше на попередніх ітераціях, що істотно скорочує час пошуку.

Процеси $Pr_1, Pr_2, \dots, Pr_{NPr-1}$ при виконанні процедури редукції даних можуть ефективно обмінюватися між собою інформацією $Inf_k = \langle Xe_k, V(Xe_k) \rangle$. Це дозволяє організувати паралельний пошук (аналогічно острівній моделі [267]) на групі процесорів, задіяних при виконанні

одного і того ж методу відбору ознак, а також не досліджувати повторно вже оцінені контрольні точки.

По завершенню процедури відбору ознак на вузлах $Pr_1, Pr_2, \dots, Pr_{NPr-1}$ виконується етап збору і розподілу поточної інформації про оптимізаційний процес. На даному етапі на головний процес Pr_0 з процесів $Pr_1, Pr_2, \dots, Pr_{NPr-1}$ надходить інформація $InformPr_j$ про множини досліджених контрольних точок (їх координати в просторі пошуку, відповідні їм значення цільової функції, а також службова інформація про методи, на яких дані точки були оцінені):

$$InformPr_j = \{Inform_1, Inform_2, \dots, Inform_{N_{\chi_j}}\}, \quad (4.36)$$

$$Inform_k = \langle \chi_k, V(\chi_k), InformLI(\chi_k), InformM(\chi_k) \rangle, \quad (4.37)$$

де $Inform_k$ – інформація про k -е рішення;

N_{χ_j} – кількість контрольних точок, досліджених на j -му процесі;

χ_k – k -е рішення, що оцінене у процесі редукції даних і відповідає k -й дослідженій контрольній точці Xe_k у просторі пошуку $XS: \chi_k \rightarrow Xe_k$;

$V(\chi_k)$ – значення цільової функції k -го рішення;

$InformLI(\chi_k)$ – прапорець, що відображає присутність рішення χ_k у множині рішень $R(iter) = \{\chi_1, \chi_2, \dots, \chi_{N_{\chi}}\}$ на останній ітерації пошуку $iter$;

$InformM(\chi_k)$ – перелік методів, на яких було оцінено рішення χ_k .

Після отримання інформації $InformPr_j$ з усіх процесів $Pr_1, Pr_2, \dots, Pr_{NPr-1}$ виконується її об'єднання на головному процесі Pr_0 : $Inform = \bigcup_{j=1}^{NPr} InformPr_j$.

Важливо відзначити, що при об'єднанні множин $InformPr_j$ можуть виникнути ситуації, коли одне і те ж рішення χ_k присутнє у різних множинах. У такому випадку в змінну $InformM(\chi_k)$ заноситься перелік всіх методів, в яких приймало участь рішення χ_k . Значення цільової функції $V(\chi_k)$ вибирається

найкращим серед оцінок, отриманих на різних процесах. Різні значення цільової функції $V(\chi_k)$ для однієї і тієї ж точки χ_k простору пошуку можуть виникати в силу того, що в якості цільової функції, як правило, використовуються помилки моделей, побудованих на основі множин ознак, що відповідають точці χ_k . При цьому в якості таких моделей можуть використовуватися штучні нейронні мережі або інші моделі обчислювального інтелекту, навчання яких виконується на основі ймовірнісних процедур, що й обумовлює деяку можливу відмінність оцінок $V(\chi_k)$ для одних і тих же значень χ_k .

Після отримання інформації $InformPr_j$ про множини досліджених контрольних точок χ_k на головному процесі Pr_0 відбувається оцінювання їх концентрованості в поточній множині рішень $R(iter) = \{\chi_1, \chi_2, \dots, \chi_{N\chi}\}$ навколо локальних екстремумів $v_{conc}(iter)$. Обчислення оцінок концентрованості рішень навколо локальних екстремумів $v_{conc}(iter)$ виконується з метою визначення рівномірності покриття простору пошуку XS у процесі відбору ознак. У разі виникнення ситуацій, коли більшість рішень χ_k групується в невеликих областях локальних оптимумів, пропонується вводити в нову множину рішень $R(iter+1)$ додаткові контрольні точки, розташовані поза локальними оптимумами.

Для обчислення оцінки $v_{conc}(iter)$ концентрованості рішень виконується розбиття поточної множини рішень $R(iter) = \{\chi_1, \chi_2, \dots, \chi_{N\chi}\}$ на групи (кластери) $Cl(iter) = \{Cl_1, Cl_2, \dots, Cl_{NCl}\}$ в залежності від їх просторового розташування. Для цього застосовуються відомі методи кластерного аналізу [57–63, 97, 98, 115].

Потім для визначення концентрованості рішень навколо областей локальних екстремумів обчислюються такі критерії:

1) середня відстань $dC(Cl_c)$ між рішеннями в конкретному кластері (4.38):

$$dC(Cl_c) = \frac{2}{|Cl_c|(|Cl_c| - 1)} \sum_{k=1}^{|Cl_c|} \sum_{u=k+1}^{|Cl_c|} d(\chi_k, \chi_u), \chi_k, \chi_u \in Cl_c, \quad (4.38)$$

де $d(\chi_k, \chi_u)$ – відстань між точками χ_k і χ_u простору пошуку XS , що належать кластеру Cl_c . Відстань $d(\chi_k, \chi_u)$ обчислюється за формулою (4.39):

$$d(\chi_k, \chi_u) = \frac{1}{M} \sum_{m=1}^M |g_{mk} - g_{mu}|, \quad (4.39)$$

де g_{mk} та g_{mu} – m -ті координати k -го та u -го рішення, відповідно;

2) дисперсія $DC(Cl_c)$ рішень χ_k у межах кластеру Cl_c – відображає середню відстань від центру $\overline{\chi_c}$ до рішень χ_k , що відносяться до кластеру Cl_c (4.40):

$$DC(Cl_c) = \frac{1}{|Cl_c|} \sum_{\chi_k \in Cl_c} d(\chi_k, \overline{\chi_c}), \quad (4.40)$$

де $d(\chi_k, \overline{\chi_c})$ – відстань між рішеннями χ_k і центром c -го кластеру $\overline{\chi_c} = \{\overline{g_{1Clc}}, \overline{g_{2Clc}}, \dots, \overline{g_{MClc}}\}$:

$$d(\chi_k, \chi_c) = \sqrt{\sum_{m=1}^M (g_{mk} - \overline{g_{mClc}})^2}, \quad (4.41)$$

$\overline{g_{mClc}}$ – m -та координата центру c -го кластеру, що обчислюється за формулою (4.42):

$$\overline{g_{mClc}} = \frac{1}{|Cl_c|} \sum_{\chi_k \in Cl_c} g_{mk}. \quad (4.42)$$

Чим менше значення критеріїв $dC(Cl_c)$ і $DC(Cl_c)$, тим більш згрупованими є рішення, зосереджені в c -му кластері Cl_c ;

3) середньокластерна відстань $dC(iter)$ між рішеннями на поточній ітерації $iter$ пошуку (4.43):

$$dC(iter) = \frac{\sum_{c=1}^{N_{Cl}} |Cl_c| dC(Cl_c)}{\sum_{c=1}^{N_{Cl}} |Cl_c|} = \frac{1}{N_\chi} \sum_{c=1}^{N_{Cl}} |Cl_c| dC(Cl_c). \quad (4.43)$$

Критерій $dC(iter)$ характеризує середню відстань між різними контрольними точками на поточній ітерації $iter$ у межах середнього кластеру;

4) середньокластерна дисперсія $DC(iter)$ рішень на поточній ітерації $iter$ пошуку (4.44):

$$DC(iter) = \frac{1}{N_\chi} \sum_{c=1}^{N_{Cl}} |Cl_c| DC(Cl_c). \quad (4.44)$$

Чим менше значення критеріїв $dC(iter)$ і $DC(iter)$, тим рішення (контрольні точки) більше згруповані навколо локальних оптимумів на поточній ітерації $iter$;

5) коефіцієнт концентрованості рішень на поточній ітерації (4.45):

$$v_{conc}(iter) = \frac{dC(iter)}{d(iter)}, \quad (4.45)$$

де $d(iter)$ – середня відстань між усіма рішеннями на поточній ітерації (4.46):

$$d(iter) = \frac{2}{N_\chi(N_\chi - 1)} \sum_{k=1}^{N_\chi} \sum_{u=k+1}^{N_\chi} d(\chi_k, \chi_u), \quad \chi_k, \chi_u \in R(iter). \quad (4.46)$$

Використовуюючи оцінки дисперсії рішень $DC(iter)$, коефіцієнт концентрованості рішень на поточній ітерації може бути також розрахований за формулою (4.47):

$$v_{conc}(iter) = \frac{DC(iter)}{D(iter)}, \quad (4.47)$$

де $D(iter)$ – дисперсія рішень на поточній ітерації (4.48):

$$D(iter) = \frac{1}{N_\chi} \sum_{k=1}^{N_\chi} d(\chi_k, \bar{\chi}), \quad (4.48)$$

де $d(\chi_k, \bar{\chi})$ – відстань між рішенням χ_k і центральним рішенням $\bar{\chi}$ на ітерації $iter$:

$$d(\chi_k, \bar{\chi}) = \sqrt{\sum_{m=1}^M (g_{mk} - \bar{g}_m)^2}, \quad (4.49)$$

\bar{g}_m – m -а координата центрального рішення $\bar{\chi}$, що обчислюється за формулою (4.50):

$$\bar{g}_m = \frac{1}{N_\chi} \sum_{k=1}^{N_\chi} g_{mk}. \quad (4.50)$$

Величина критерію $v_{conc}(iter)$ знаходиться в інтервалі $(0;1)$. Чим ближче цей критерій до одиниці, тим менш згрупованими є рішення (відповідно, простір пошуку покрито контрольними точками більш рівномірно). Значення критерію $v_{conc}(iter)$, близькі до нуля, свідчать про суттєву концентрацію рішень навколо локальних екстремумів.

б) максимальна кількість контрольних точок $\chi_k \in Cl_c$, згрупованих у межах одного локального екстремуму (в області кластеру Cl_c):

$$N_{\max Ncl}(iter) = \max_{c=1,2,\dots,N_{Cl}} (|Cl_c|). \quad (4.51)$$

Чим більше величина критерію $N_{\max Ncl}(iter)$, тим більша кількість рішень згрупована в межах одного локального екстремуму, і, відповідно, тим менш рівномірно розподілені рішення в просторі пошуку XS на ітерації $iter$.

При прийнятті рішень про надмірну концентрацію контрольних точок навколо деяких областей локальних екстремумів у розробленому методі редукції даних пропонується використовувати інтегральний критерій $v_{conc}(iter)$, а також критерій $N_{\max Ncl}(iter)$ максимальної кількості контрольних точок $\chi_k \in Cl_c$, згрупованих у межах одного локального екстремуму.

У випадку, якщо значення хоча б одного з даних критеріїв вище заданого порогового значення ($v_{conc}(iter) > v_{concThr}$ або $N_{\max Ncl}(iter) > N_{\max NclThr}$), приймається рішення про надмірну концентрацію контрольних точок в областях локальних екстремумів. Для підвищення рівномірності покриття простору пошуку пропонується вводити в поточну множину рішень $R(iter+1)$ додаткові контрольні точки χ_a , розташовані поза локальними оптимумами. Пропонується формувати таку ж кількість додаткових контрольних точок, як і кількість вже наявних рішень у множині $R(iter)$.

Для цього обчислюються середні значення $\overline{g_m}$ m -х координат центрального рішення $\overline{\chi}$, використовуючи формулу (4.50). Значення $\overline{g_m}$ відображають локальну концентрованість рішень в проекції вісі m -ої ознаки. Чим ближче значення $\overline{g_m}$ до одиниці, тим більша кількість рішень χ_k характеризує m -у ознаку як інформативну. Аналогічно, при $\overline{g_m} \rightarrow 0$, m -а ознака вважається неінформативною в наборі рішень $R(iter) = \{\chi_1, \chi_2, \dots, \chi_{N_\chi}\}$.

Потім на основі обчислених значень $\overline{g_m}$ і випадково згенерованого числа $rand[0;1]$ відбувається створення нових рішень $\chi_a = \{g_{1a}, g_{2a}, \dots, g_{Ma}\}$, m -а координата g_{ma} яких визначається за формулою (4.52):

$$g_{ma} = \begin{cases} 1, & rand[0;1] > \overline{g_m}; \\ 0, & rand[0;1] \leq \overline{g_m}, \end{cases} \quad (4.52)$$

де $rand[0;1]$ – випадково згенероване число в інтервалі $[0;1]$.

Таким чином, m -а координата g_{ma} нової контрольної точки χ_a матиме тим більшу ймовірність прийняти значення $g_{ma} = b$, чим менше рішень χ_k у множині $R(iter) = \{\chi_1, \chi_2, \dots, \chi_{N_\chi}\}$ мають таке ж значення m -ої координати. Такий підхід дозволить генерувати нові рішення χ_a , істотно віддалені від поточної множини рішень $R(iter) = \{\chi_1, \chi_2, \dots, \chi_{N_\chi}\}$, що, в свою чергу, буде знижувати концентрованість рішень у процесі редукції даних і збільшувати рівномірність покриття простору пошуку.

З метою закріплення значень m -х координат, що відповідають ознакам, які суттєво впливають на значення вихідного параметра, пропонується використовувати апріорну інформацію про індивідуальну інформативність ознак. Для цього на етапі ініціалізації пропонується обчислити значення індивідуальних інформативностей $V(p_m)$ ознак p_m , що характеризують

взаємозв'язок ознаки p_m з вихідним параметром T . В якості оцінок $V(p_m)$ можуть використовуватися значення коефіцієнту парної кореляції, ентропії ознаки, критерію кореляції знаків тощо [126–132, 195–203]. При використанні апріорної інформації про індивідуальну значущість ознак формулу (4.52) можна модифікувати таким чином:

$$g_{ma} = \begin{cases} 1, & \text{rand}[-1;1] > (\overline{g_m} - V(p_m)); \\ 0, & \text{rand}[-1;1] \leq (\overline{g_m} - V(p_m)). \end{cases} \quad (4.53)$$

Такий підхід дозволить підвищити ймовірність генерації нових рішень χ_a з генами g_{ma} , які відповідають високоінформативним ознакам p_m . При цьому за рахунок імовірнісного підходу зберігається можливість генерації рішень χ_a , віддалених від поточної множини контрольних точок $R(iter) = \{\chi_1, \chi_2, \dots, \chi_{N_\chi}\}$.

Після цього на ядрах $Pr_1, Pr_2, \dots, Pr_{NPr-1}$ відбувається перезапуск процедури редукції даних. При цьому нові початкові множини рішень $R_j(iter+1)$ для відповідних методів відбору ознак формуються на основі множини $R(iter+1)$. Формування множин $R_j(iter+1)$ на вузлах Pr_j відбувається наступним чином. Спочатку відбираються рішення $\chi_{elit,j}$, які на попередній ітерації характеризувалися найкращим значенням цільової функції: $V(\chi_{elit,j}) = \max_{\chi_k \in R_j(iter)} (V(\chi_k))$. Таким чином так звані елітні рішення $\chi_{elit,j}$, що характеризуються найкращими значеннями цільової функції V автоматично переносяться в наступну популяцію $R_j(iter+1)$, що забезпечує використання результатів, отриманих на попередніх ітераціях і наближення нових початкових точок пошуку до оптимальних. Кількість елітних рішень $\chi_{elit,j}$, що автоматично переносяться на наступну ітерацію пошуку, задається користувачем на етапі ініціалізації методу, і, як правило, становить 2-5% від загальної кількості

рішень, використуваних на конкретному вузлі обчислювальної системи. Потім з множини $R(\text{iter} + 1)$ випадковим чином вибираються рішення χ_k , загальна кількість яких вибирається з потреб методу відбору ознак, що використовується на j -му ядрі Pr_j обчислювальної системи.

Потім на основі початкових множин контрольних точок $R_j(\text{iter} + 1)$ на ядрах $Pr_1, Pr_2, \dots, Pr_{NPr-1}$ виконуються процедури редукції даних.

Описаний процес триває до тих пір, поки не буде досягнутий один з критеріїв зупинення пошуку:

- $Crit_1$ – успішне знаходження комбінації ознак P^* , що задовольняє заданим мінімально прийнятним умовам пошуку;

- $Crit_5$ – перевищення загального максимально допустимого часу пошуку на паралельній системі;

- $Crit_6$ – досягнення максимально допустимого числа перезапусків процедури редукції даних на ядрах $Pr_1, Pr_2, \dots, Pr_{NPr-1}$.

Таким чином, запропонований паралельний стохастичний метод відбору ознак передбачає використання різних стратегій стохастичного пошуку, що ґрунтуються на еволюційному і мультиагентному підходах та реалізуються на різних вузлах паралельної системи. Використання різних стратегій, що ґрунтуються на імовірнісному підході, дозволяє істотно розширити покриття простору пошуку. Для підвищення рівномірності покриття простору пошуку в розробленому методі запропоновано в процесі пошуку вводити в поточну множину рішень додаткові контрольні точки, розташовані поза зоною локальних оптимумів. Застосування паралельних обчислень у запропонованому методі дозволяє скоротити час пошуку, і, як наслідок, збільшити практичний поріг застосовуваності методів відбору ознак при обробці великих обсягів даних.

Запропоновано систему критеріїв, що дозволяють оцінювати концентрованість контрольних точок навколо локальних екстремумів.

Обчислення оцінок концентрованості рішень у розробленій системі критеріїв засноване на просторовому розташуванні контрольних точок в поточній множині рішень. Запропонована система критеріїв може використовуватися в методах стохастичного пошуку для відстеження ситуацій надмірної концентрації рішень в областях локальних оптимумів, і, як наслідок, для підвищення різноманітності множини рішень в поточній популяції і більш рівномірного покриття простору пошуку контрольними точками в процесі оптимізації.

4.3 Висновки за розділом 4

У розділі розв'язано актуальне завдання автоматизації процесу редукції великих масивів даних при вирішенні задач діагностування та розпізнавання образів.

Запропоновано систему критеріїв оцінювання інформативності ознак, яка передбачає визначення значущості ознак виходячи з просторового розташування екземплярів різних класів (діапазонів зміни значень вихідного параметра). Розроблена система критеріїв дозволяє оцінювати індивідуальну і групову інформативність ознак при розв'язанні задач діагностування в умовах, коли вихідні вибірки даних містять надлишкові і взаємозалежні ознаки, а також екземпляри з пропущеними значеннями. Запропоновані критерії не вимагають побудови моделей на основі оцінюваних комбінацій ознак, що істотно знижує часові й обчислювальні витрати в процесі відбору інформативних ознак. Використання запропонованих критеріїв для оцінювання та відбору інформативних ознак дозволяє при розв'язанні задач діагностування знижувати структурну складність синтезованих діагностичних моделей, підвищувати їх

інтерпретовність та узагальнювальні здібності за рахунок виключення малозначущих, взаємозалежних і надлишкових ознак.

Розроблено паралельний стохастичний метод редукції даних, який передбачає використання різних стратегій стохастичного пошуку, що ґрунтуються на еволюційному і мультиагентному підходах та реалізуються на різних вузлах паралельної системи, що дозволяє розширити покриття простору пошуку. Розроблений метод передбачає в процесі редукції даних оцінювання концентрованості контрольних точок навколо локальних екстремумів, яке засноване на просторовому розташуванні точок в поточній множині рішень, що дозволяє відстежувати надмірну концентрацію рішень в областях локальних оптимумів. Для підвищення рівномірності покриття простору пошуку в поточну множину рішень вводяться додаткові контрольні точки, розташовані поза зоною локальних оптимумів, що дозволяє підвищити різноманітність множини рішень поточної популяції. Застосування паралельних обчислень у запропонованому методі дозволяє скоротити час пошуку, і, як наслідок, збільшити практичний поріг застосовуваності методів відбору ознак при обробці великих обсягів даних.

Список використаних джерел у цьому розділі наведено у повному списку використаних джерел під номерами [50, 55–63, 77, 97, 98, 105, 115, 126–132, 195–216, 267–269, 293–325].

5 СИНТЕЗ НЕЙРО-НЕЧІТКИХ ДІАГНОСТИЧНИХ МОДЕЛЕЙ НА ОСНОВІ ПАРАЛЕЛЬНОГО СТОХАСТИЧНОГО ПОШУКУ

Розроблення інтелектуальних систем діагностування в техніці та медицині, неруйнівного контролю якості продукції, а також систем розпізнавання образів пов'язано з необхідністю синтезу моделей досліджуваних об'єктів або процесів [1, 6, 9, 24, 57–63]. Як діагностичні моделі ефективно можуть використовуватися нейро-нечіткі мережі [217–219, 249–256], у яких реалізується система нечіткого виведення у вигляді нейромережі, зручної для аналізу, використання і поповнення знань.

Для навчання нейро-нечітких мереж, як правило, використовують метод зворотного поширення помилки [217–219, 241, 242], який залежить від вибору початкової точки пошуку, вимагає завдання похідної цільової функції (при програмній реалізації складним є врахування можливості настроювання параметрів нейро-нечітких мереж по цільовим функціям, що задаються користувачем), має низьку швидкість, що при обмеженому часі та кількості ітерацій не завжди дозволяє на практиці досягати прийнятної точності.

У цьому розділі для навчання нейро-нечітких мереж пропонується використовувати методи стохастичного пошуку [204–207, 211, 267–269], що на основі процедур адаптації деякої множини рішень (точок у просторі пошуку) дозволяють знаходити прийнятні рішення без необхідності обчислення похідних цільової функції, а також мають природний паралелізм обчислень.

Однак такі методи, хоча й в істотно меншому ступені, ніж градієнтні методи, також залежать від формування початкової множини рішень (вибору початкових точок пошуку), що, як правило, відбувається випадковим чином, а також мають низьку швидкість пошуку оптимальних рішень. Тому актуальною задачею є розробка нового методу випадкового пошуку для параметричного синтезу нейро-нечітких мереж, вільного від зазначених недоліків. Природний

паралелізм обчислень, властивий методам випадкового пошуку, а також їхня низька швидкість збіжності обумовлюють доцільність розпаралелювання таких методів з урахуванням особливостей розв'язуваної задачі.

Метою цього розділу є створення методу параметричної ідентифікації нейро-нечітких моделей на основі паралельного випадкового пошуку.

5.1 Модель подання стохастичного пошуку у ярусно-паралельній формі для параметричного синтезу нейро-нечітких мереж

Як відзначено вище, для навчання гібридних моделей обчислювального інтелекту ефективно можуть застосовуватися методи стохастичного пошуку, зокрема еволюційні методи [204–207, 211, 267–269].

Однак для одержання прийнятних результатів (моделей, що забезпечують прийнятну точність розпізнавання або прогнозування) однократного запуску таких методів, як правило, недостатньо, що обумовлено використанням імовірнісного підходу і зацикленням у деяких випадках у локальних оптимумах.

Необхідність багаторазового запуску, а також істотний час пошуку обумовлюють доцільність розпаралелювання процесу навчання гібридних інтелектуальних моделей, у тому числі і нейро-нечітких мереж.

З метою розробки паралельного методу випадкового пошуку для навчання нейро-нечітких моделей представимо процес параметричного синтезу в ярусно-паралельній формі [323]. Для цього виділимо етапи випадкового пошуку, що раціонально розпаралелити. Як відомо [204–207, 211, 267–269], основними етапами стохастичних методів є:

– ініціалізація початкової множини рішень $R^{(0)}$ (5.1):

$$R^{(0)} = \{\chi_1^{(0)}, \chi_2^{(0)}, \dots, \chi_{N_\chi}^{(0)}\}, \quad (5.1)$$

де $\chi_k^{(0)} = \{g_{1k}^{(0)}, g_{2k}^{(0)}, \dots, g_{N_g k}^{(0)}\}$ – k -те рішення в множині $R^{(0)}$, $k = 1, 2, \dots, N_\chi$;

N_χ – кількість елементів множині $R^{(0)}$ (кількість випадково згенерованих рішень при ініціалізації), як правило, величина N_χ не змінюється в процесі ймовірнісної оптимізації;

$g_{lk}^{(0)}$ – значення l -го елемента (параметру) у k -му рішенні, $l = 1, 2, \dots, N_g$;

N_g – кількість параметрів у рішенні $\chi_k^{(i)}$;

– оцінювання поточної (i -ї) множини рішень $R^{(i)}$ (5.2):

$$G^{(i)} = G(R^{(i)}), \quad (5.2)$$

де G – цільова функція, що дозволяє оцінити якість i -ї множини рішень $R^{(i)}$;

– перевірка критеріїв зупинення;

– формування нової множини рішень $R^{(i+1)}$. При використанні еволюційного пошуку даний етап виконується за допомогою застосування операторів схрещування і мутації.

Для скорочення часу випадкового пошуку при побудові гібридних моделей обчислювального інтелекту доцільно на етапі ініціалізації при створенні початкової множини рішень використовувати апріорну інформацію про навчальну вибірку. Отже, при такому підході буде потрібно N_χ разів синтезувати гібридні моделі (сформувані множини початкових значень їхніх параметрів), що вимагає значних комп'ютерних ресурсів і обумовлює необхідність розпаралелювання даного етапу.

Найбільш ресурсномістким, як правило, є етап оцінювання поточної множини рішень $R^{(i)}$, на якому затрачається велика кількість комп'ютерних і

часових ресурсів при обчисленні значень цільової функції G для кожного k -го ($k = 1, 2, \dots, N_\chi$) рішення $\chi_k^{(i)}: G_k^{(i)} = G(\chi_k^{(i)})$. Оскільки даний етап має високу складність, виконується повільно і не вимагає обміну даними між рішеннями $\chi_k^{(i)}$, його раціонально виконувати паралельно.

Важливим етапом є створення нової множини рішень $R^{(i+1)}$. З метою більш детального дослідження областей локальних оптимумів доцільним є розбиття поточної множини рішень $R^{(i)}$ на підмножини $R^{(i,j)}$ з наступним пошуком оптимуму в кожній з них (5.3):

$$R^{(i)} \rightarrow \{R^{(i,1)}, R^{(i,2)}, \dots, R^{(i,N_{pr})}\}, \quad (5.3)$$

де $R^{(i,j)}$ – j -та підмножина i -ї множини $R^{(i)}$;

N_{pr} – кількість процесів, одночасно виконуваних у паралельній комп'ютерній системі.

Розбиття (5.3) пропонується виконувати з урахуванням апріорної інформації про розташування рішень $\chi_k^{(i)}$ у просторі елементів g_l ($l = 1, 2, \dots, N_g$) [324]. Такий підхід, на відміну від застосування острівної моделі еволюційного пошуку [267], що припускає випадкове формування підпопуляцій $R^{(i,j)}$, дозволяє враховувати інформацію про просторове розташування рішень $\chi_k^{(i)}$ у множини $R^{(i)}$ і більш детально досліджувати області можливих оптимумів. Кількість рішень $|R^{(i,j)}|$ у кожній підмножині $R^{(i,j)}$ визначається як відношення загальної кількості рішень N_χ у множини $R^{(i)}$ до кількості процесів N_{pr} (5.4):

$$|R^{(i,j)}| = N_\chi / N_{pr}. \quad (5.4)$$

Таким чином, задача розбиття (5.3) зводиться до необхідності формування N_{pr} підмножин $R^{(i,j)}$ (кожна з яких складається з $|R^{(i,j)}|$ рішень) у заданому просторі елементів g_l ($l = 1, 2, \dots, N_g$) (5.5):

$$R^{(i,j)} = \left\{ \chi_1^{(i,j)}, \chi_2^{(i,j)}, \dots, \chi_{|R^{(i,j)}|}^{(i,j)} \right\}, \quad j = 1, 2, \dots, N_{pr}. \quad (5.5)$$

Випадковий пошук з адаптацією в кожній j -й підмножині $R^{(i,j)}$ пропонується виконувати на j -му процесі паралельної комп'ютерної системи ($j = 1, 2, \dots, N_{pr}$) протягом N_{it} ітерацій.

Після виконання N_{it} ітерацій випадкового пошуку над кожною підмножиною $R^{(i,j)}$ виконується їхнє об'єднання $R^{(i')} = R^{(i',1)} \cup R^{(i',2)} \cup \dots \cup R^{(i',N_{pr})}$ в єдину популяцію з подальшим проведенням імовірнісної оптимізації над об'єднаною множиною. Це дозволить виявляти нові області, що містять локальні (можливо, і глобальний) оптимуми. З метою скорочення часу імовірнісної оптимізації при роботі з об'єднаною множиною рішень пропонується обчислення значень цільової функції $G_k^{(i)}$ рішень $\chi_k^{(i)}$ виконувати на процесах у паралельній системі (розпаралелити).

Виходячи з відзначеного вище, представимо граф процесу параметричного синтезу нейро-нечітких моделей у ярусно-паралельній формі (рис. 5.1). Починаючи з ярусу перевірки критеріїв зупинення процес виконується ітеративно.

На рис. 5.1 операція $RS(R)$ являє собою випадковий пошук у множині рішень R . Остання операція на графі – $RS(R^{(i)})$ виконується паралельно. Одна ітерація процесу випадкового пошуку $RS(R^{(i)})$ у ярусно-паралельній формі наведена на рис. 5.2.

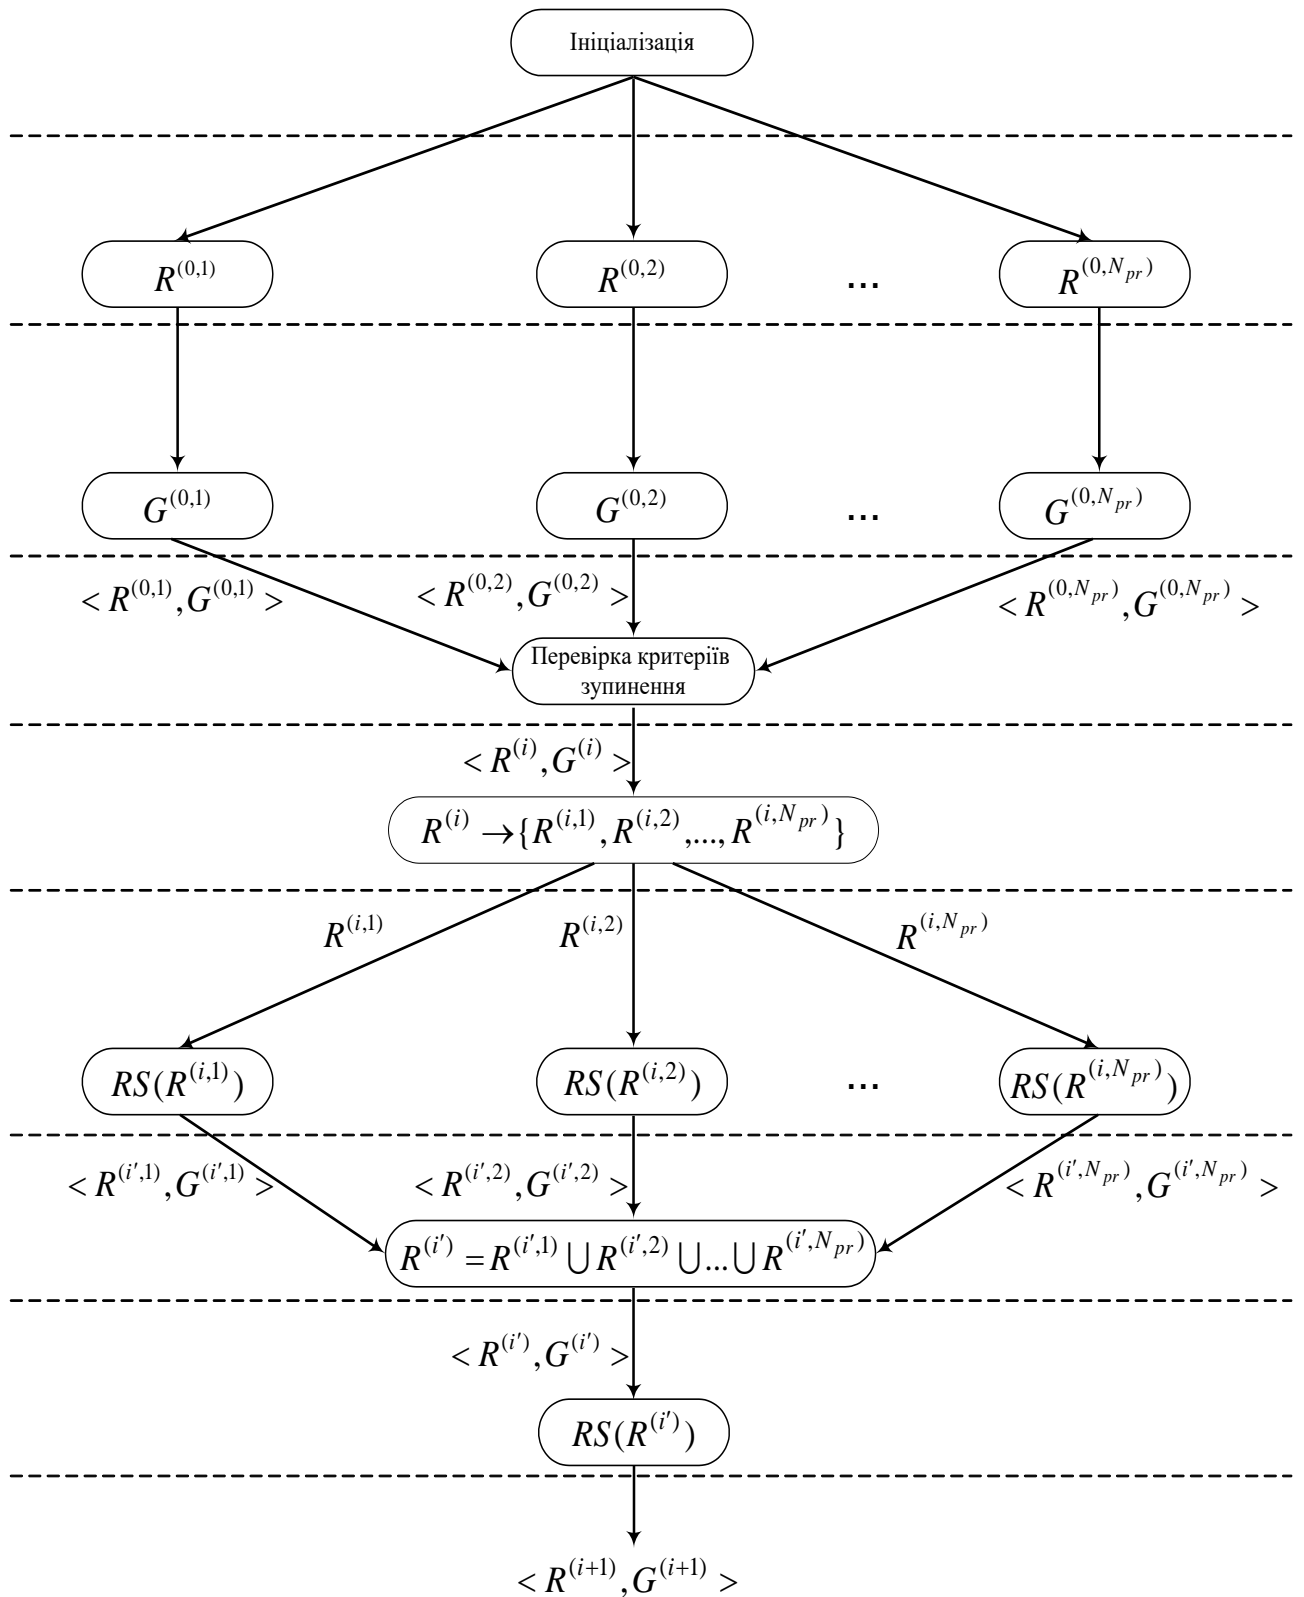


Рисунок 5.1 – Граф процесу параметричного синтезу нейро-нечітких мереж у ярусно-паралельній формі

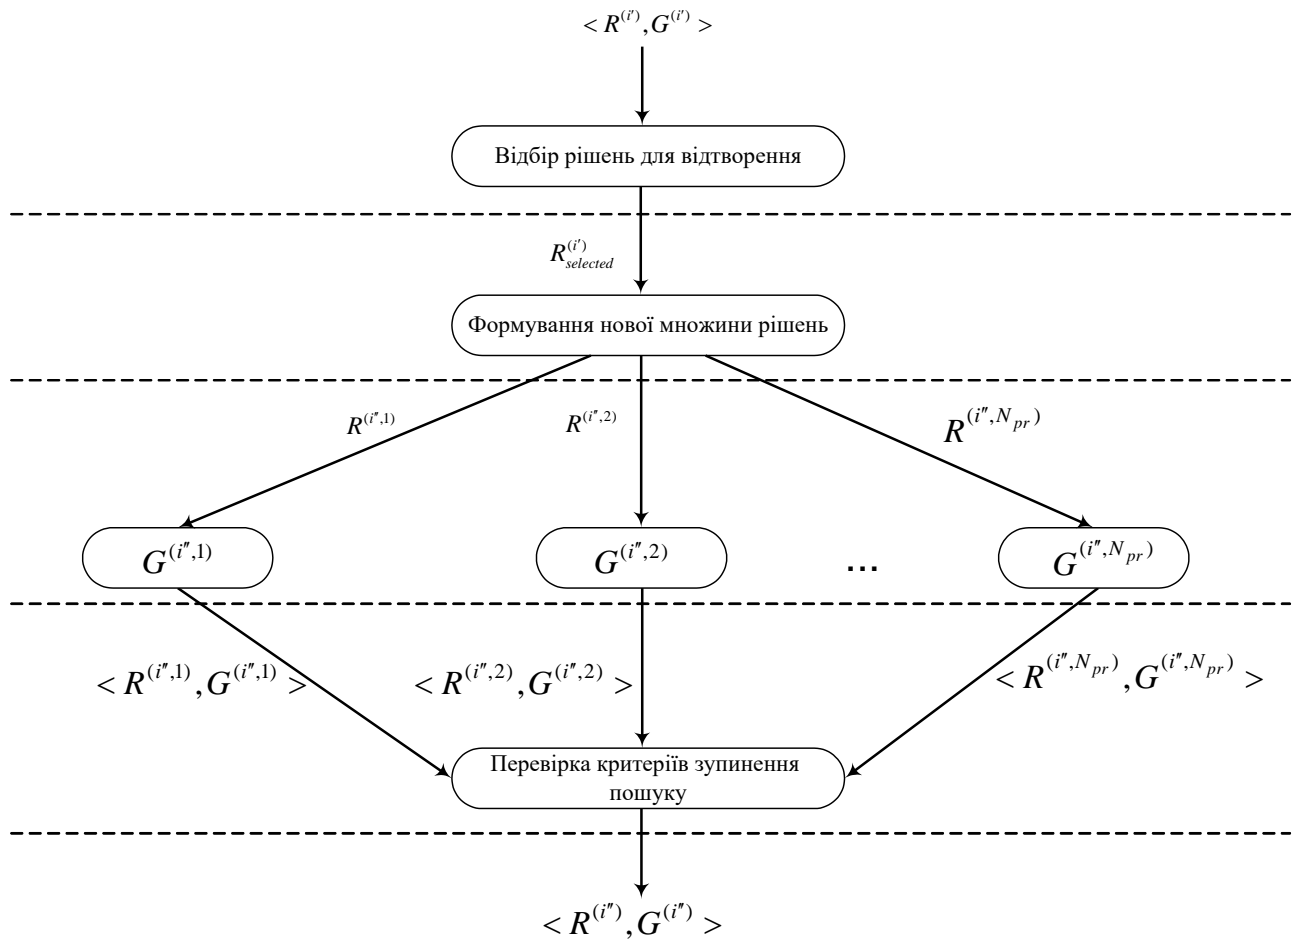


Рисунок 5.2 – Граф однієї ітерації випадкового пошуку $RS(R^{(i')})$

Пунктирні лінії на рис. 5.1 та рис. 5.2 відокремлюють яруси графа один від одного. Операції на одному ярусі графа виконуються паралельно. Дуги графа показують залежності між операціями. Так, не можна приступити до виконання будь-якої операції поки не завершаться інші операції, дуги з яких орієнтовані у вершини цієї операції.

Перехід між ярусами, при якому від однієї вершини графа дуги орієнтовані в декілька вершин наступного ярусу, пов'язаний з необхідністю розсилання рішень по процесах. Перехід іншого типу, при якому дуги орієнтовані від декількох вершин одного ярусу до однієї вершини наступного ярусу, виконується за допомогою збору рішень у головному процесі.

Як видно з рис. 5.1 та рис. 5.2, найбільш ресурсномісткі операції, а саме ініціалізація початкової множини рішень, оцінювання поточної множини рішень, випадковий пошук у підмножині рішень, виконуються одночасно на процесах паралельної системи.

Запропонована модель подання стохастичного пошуку у ярусно-паралельній формі для параметричного синтезу нейро-нечітких мереж відрізняється використанням апріорної інформації про навчальну вибірку та просторове розташування рішень, що дозволяє більш детально досліджувати області можливих оптимумів та скоротити час настроювання параметрів синтезованих діагностичних нейромоделей.

5.2 Метод параметричної ідентифікації нейро-нечітких моделей на основі паралельного випадкового пошуку

Запропонований паралельний метод параметричної ідентифікації нейро-нечітких моделей [325] заснований на запропонованій вище моделі синтезу нейро-нечітких мереж і використовує ймовірнісну оптимізацію для настроювання параметрів синтезованих нейромереж.

5.2.1 Кодування рішень

Вхідною інформацією для параметричного синтезу гібридних моделей обчислювального інтелекту є множина спостережень $S = \langle P, T \rangle$, а також структура моделі. Кількість параметрів N_g , що налаштовуються (параметрів використовуваних функцій належності і вагових коефіцієнтів нейроелементів)

нейро-нечітких моделей залежить від кількості використовуваних нейронів, що у свою чергу визначається виходячи з продукційних правил, які описують множину S .

З метою використання випадкового пошуку для параметричної ідентифікації нейро-нечітких моделей визначимо спосіб подання значень параметрів g_{lk} , що налаштовуються, у рішеннях (при еволюційному пошуку – хромосомах χ_k) [326–331]. Нехай з вибірки $S = \langle P, T \rangle$ виділено N_R продукційних правил. Як базис для синтезованої моделі доцільно використовувати нейро-нечітку мережу ANFIS [217, 249–256], що одержала широке поширення при розв’язанні задач діагностування та розпізнавання образів [217, 249–256] і реалізує систему нечіткого логічного виведення Такагі-Сугено у виді нейронної мережі прямого поширення, що складається з п’яти шарів.

Синтез моделі на основі мережі ANFIS полягає в підборі значень параметрів нечітких термів і правил. Розроблений метод може аналогічним чином застосовуватися для параметричного синтезу інших видів гібридних моделей обчислювального інтелекту (для цього досить лише визначити параметри, що налаштовуються, і спосіб їхнього подання в рішенні χ_k).

Виходи нейронів першого шару нейро-нечіткої мережі ANFIS визначають належність розпізнаваного екземпляра до нечітких термів ознак з функціями належності $\mu_{mn}^{(1)}$ ($\mu_{mn}^{(1)}$ – функція належності розпізнаваного екземпляра до n -го терму m -ї ознаки p_m , $m = 1, 2, \dots, M$, $n = 1, 2, \dots, N_{\text{int}}$, N_{int} – кількість термів ознак). Термом будемо вважати інтервал значень ознаки, що відповідає деякому поняттю, категорії або проекції кластера на вісь ознаки.

Як функції належності нейронів першого шару доцільно вибрати П-подібну (5.6) чи трапецієподібну (5.7) [217–219, 249–256], оскільки вони є універсальними на класі елементарних функцій належності (тобто з них можна скласти інші функції):

$$\mu_{mn}^{(1)} = \mu_{S_{mn}}^{(1)} \cdot \mu_{Z_{mn}}^{(1)}, \quad (5.6)$$

$$\mu_{mn}^{(1)} = \begin{cases} 0, & p_m < c_{mn}; \\ \frac{p_m - c_{mn}}{a_{mn} - c_{mn}}, & c_{mn} \leq p_m < a_{mn}; \\ 1, & a_{mn} \leq p_m \leq b_{mn}; \\ \frac{d_{mn} - p_m}{d_{mn} - b_{mn}}, & b_{mn} < p_m \leq d_{mn}; \\ 0, & p_m > d_{mn}, \end{cases} \quad (5.7)$$

де a_{mn} , b_{mn} , c_{mn} , d_{mn} – параметри функції належності μ_{mn} m -ї ознаки p_m n -му терму;

$\mu_{S_{mn}}^{(1)}$ і $\mu_{Z_{mn}}^{(1)}$ – S -подібна (5.8) і Z -подібна (5.9) функції належності:

$$\mu_{S_{mn}}^{(1)} = \begin{cases} 0, & p_m < c_{mn}; \\ \frac{p_m - c_{mn}}{a_{mn} - c_{mn}}, & c_{mn} \leq p_m < a_{mn}; \\ 1, & p_m \geq a_{mn}, \end{cases} \quad (5.8)$$

$$\mu_{Z_{mn}}^{(1)} = \begin{cases} 1, & p_m \leq b_{mn}; \\ \frac{d_{mn} - p_m}{d_{mn} - b_{mn}}, & b_{mn} < p_m \leq d_{mn}; \\ 0, & p_m > d_{mn}. \end{cases} \quad (5.9)$$

Параметри a_{mn} і b_{mn} функцій $\mu_{mn}^{(1)}$ вибираються виходячи з границь інтервалів розбиття значень ознаки $p_m \in [p_{m \min}; p_{m \max}]$. Тому параметрами, що налаштовуються, будуть c_{mn} та d_{mn} для кожного з $M \cdot N_{\text{int}}$ нейронів першого шару.

На другому шарі реалізуються ліві частини (антецеденти) правил. Виходи нейронів цього шару можуть бути розраховані за формулою (5.10):

$$\mu_r^{(2)} = \prod_{m=1}^M \prod_{n=1}^{N_{\text{int}}} w_{mn}^{(2,r)} \mu_{mn}^{(1)}, \quad r = 1, 2, \dots, N_R, \quad (5.10)$$

де $w_{mn}^{(2,r)}$ – параметри, що відображають наявність зв'язку між відповідними нейронами першого і другого шарів і визначаються виходячи з заданої структури мережі ($w_{mn}^{(2,r)} = 0$ у випадку, якщо n -й терм m -ї ознаки не входить в антецедент r -го правила; $w_{mn}^{(2,r)} = 1$ при наявності відповідного терма ознаки в умові r -го правила). Крім наведеної формули (5.10) значення виходів нейронів другого шару $w_{mn}^{(2,r)}$ можуть бути визначені як мінімум добутків $w_{mn}^{(2,r)} \mu_{mn}^{(1)}$, $m = 1, 2, \dots, M$, $n = 1, 2, \dots, N_{\text{int}}$.

Нейрони третього шару нормують значення ступенів виконання антецедентів правил (5.11):

$$\mu_r^{(3)} = \frac{1}{\sum_{z=1}^{N_R} \mu_z^{(2)}} \mu_r^{(2)}, \quad r = 1, 2, \dots, N_R. \quad (5.11)$$

Отже, на другому і третьому шарах відсутні параметри, що вимагають настроювання за допомогою випадкового пошуку.

Кожен r -й нейрон четвертого шару визначає консеквент відповідного правила (5.12):

$$y_r = \mu_r^{(4)} = \mu_r^{(3)} \sum_{m=1}^M w_m^{(4,r)} p_m, \quad r = 1, 2, \dots, N_R. \quad (5.12)$$

де $w_m^{(4,r)}$ – вагові коефіцієнти, що визначають значущість ознаки p_m в r -му правилі і є параметрами нейро-нечіткої моделі, що налаштовуються.

П'ятий шар містить один нейрон, на якому обчислюється загальний вихід мережі (5.13):

$$y = \sum_{r=1}^{N_R} y_r \cdot \quad (5.13)$$

Синтезована нейро-нечітка мережа ANFIS наведена на рис. 5.3.

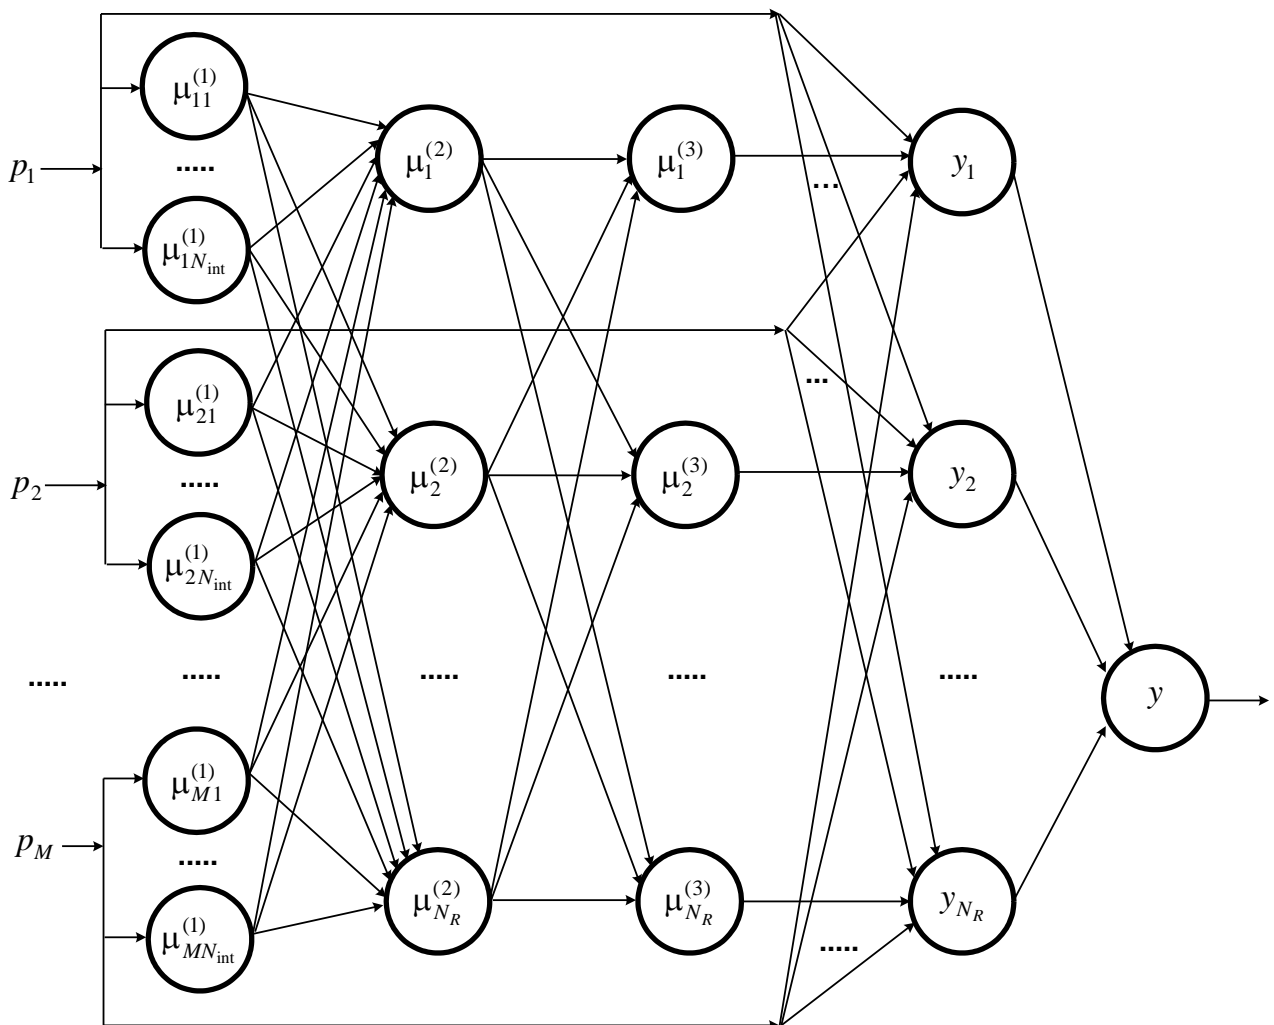


Рисунок 5.3 – Структура нейро-нечіткої мережі ANFIS, синтезованої за допомогою запропонованого методу

Таким чином, параметрами, що налаштовуються, при параметричному синтезі нейро-нечітких моделей є: $M \cdot N_{\text{int}}$ параметрів c_{mn} і d_{mn} функцій належності $\mu_{mn}^{(1)}$ нейронів першого шару і $M \cdot N_R$ вагових коефіцієнтів $w_m^{(4,r)}$ нейронів четвертого шару. Отже, загальна кількість параметрів N_g , що налаштовуються, може бути визначена за формулою (5.14):

$$N_g = M \cdot N_{\text{int}} + M \cdot N_R = M(N_{\text{int}} + N_R). \quad (5.14)$$

Рішення (хромосому) χ_k при параметричному синтезі нейро-нечітких мереж з урахуванням того, що доцільним є налаштування параметрів тільки першого і четвертого шарів, можна представити у вигляді рис. 5.4.

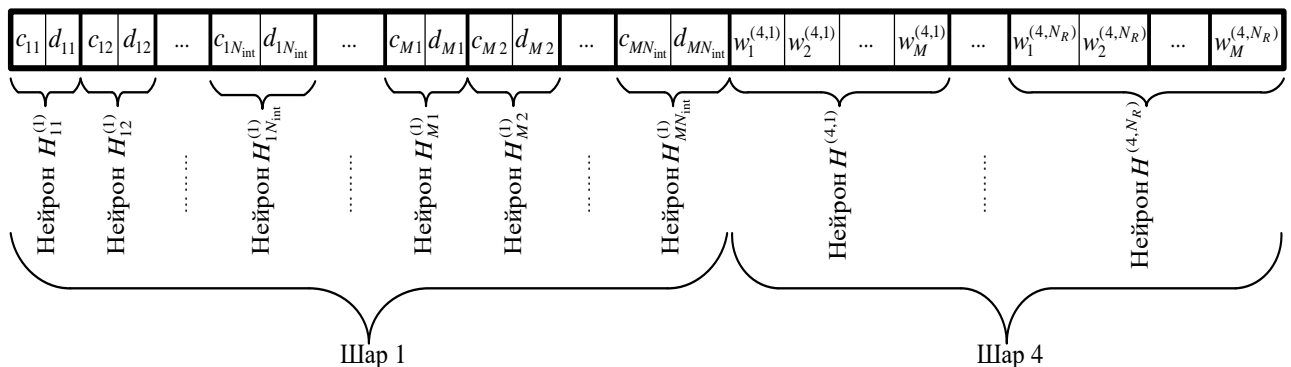


Рисунок 5.4 – Схематичне подання рішення χ_k при параметричній ідентифікації нейро-нечітких мереж

Запропонований спосіб подання (рис. 5.4) дозволяє виконувати параметричну ідентифікацію нейро-нечітких мереж за допомогою випадкового пошуку.

5.2.2 Ініціалізація

На етапі ініціалізації запропонованого методу задаються вхідні параметри (множина $S = \langle P, T \rangle$, структура нейро-нечіткої мережі, для якої необхідно виконати параметричну ідентифікацію, а також набір параметрів, необхідних для випадкового пошуку). Для наближення початкових точок пошуку $\chi_k^{(0)} = \{g_{1k}^{(0)}, g_{2k}^{(0)}, \dots, g_{N_g k}^{(0)}\}$ ($k = 1, 2, \dots, N_\chi$) до оптимальної області множини $R^{(0)}$, на відміну від відомих методів випадкового пошуку [204–207, 211, 267–269], будемо формувати з урахуванням апріорної інформації про навчальну вибірку $S = \langle P, T \rangle$. Для цього діапазон значень $\Delta p_m = [p_{m \min}; p_{m \max}]$ кожної m -ї ознаки p_m ($m = 1, 2, \dots, M$) розбивається на задану кількість інтервалів N_{int} . У такий спосіб формуються інтервали $\Delta p_{mn} = [p_{mn \min}; p_{mn \max}]$ ($n = 1, 2, \dots, N_{\text{int}}$), на основі границь яких визначаються параметри нечітких термів.

При обчисленні значень параметрів c_{mn} і d_{mn} будемо враховувати значущість n -го терму Δp_{mn} m -ї ознаки p_m для розпізнавання екземплярів вибірки $S = \langle P, T \rangle$. Значущість (інформативність, важливість) V_{mn} n -го терму m -ї ознаки визначимо як добуток величин $\frac{Q|_{p_m \in \Delta p_{mn}}}{Q}$ і $(1 - \text{Entr}(\Delta p_{mn}))$, що характеризують, відповідно, щільність розташування екземплярів множини S в інтервалі Δp_{mn} ознаки p_m і ступінь впливу терму Δp_{mn} на значення вихідного параметра T (5.15):

$$V_{mn} = \frac{Q|_{p_m \in \Delta p_{mn}}}{Q} (1 - \text{Entr}(\Delta p_{mn})), \quad (5.15)$$

де $Q|_{p_m \in \Delta p_{mn}}$ – кількість спостережень вибірки S , значення m -х ознак p_m яких потрапили в інтервал Δp_{mn} ;

$Entr(\Delta p_{mn})$ – ентропія інтервалу Δp_{mn} – величина [45, 47, 48, 57–63], що характеризує міру невизначеності вихідного параметра T за умови, що $p_m \in \Delta p_{mn}$. Чим більшою є ентропія інтервалу, тим менш інформативним він є для прийняття рішень. Величина $Entr(\Delta p_{mn})$ обчислюється за формулою (5.16):

$$Entr(\Delta p_{mn}) = - \sum_{q=1}^{N_{Q, p_m \in \Delta p_{mn}}} \rho_q \log \rho_q, \quad (5.16)$$

де $N_{Q, p_m \in \Delta p_{mn}}$ – кількість інтервалів розбиття (класів) вихідного параметра T фрагмента вибірки $S_{p_m \in \Delta p_{mn}}$, у якому значення m -х ознак p_m потрапили в інтервал Δp_{mn} ;

ρ_q – імовірність (5.17) того, що вихідний параметр T прийме значення q у множини $S_{p_m \in \Delta p_{mn}}$ (за умови, що $p_m \in \Delta p_{mn}$):

$$\rho_q = \frac{Q|_{T=q; S_{p_m \in \Delta p_{mn}}}}{Q|_{p_m \in \Delta p_{mn}}}, \quad (5.17)$$

де $Q|_{T=q; S_{p_m \in \Delta p_{mn}}}$ – кількість спостережень у множини $S_{p_m \in \Delta p_{mn}}$, у яких значення вихідного параметра T дорівнює q ($T = q$).

З метою приведення значень значущостей V_{mn} термів ознак p_m до єдиного інтервалу $[0;1]$, виконаємо їхнє нормування, використовуючи формулу (5.18):

$$V_{mn} = \frac{V_{mn} - V_{m \min}}{V_{m \max} - V_{m \min}}, \quad m = 1, 2, \dots, M, \quad n = 1, 2, \dots, N_{\text{int}}, \quad (5.18)$$

де $V_{m \min}$ і $V_{m \max}$ – відповідно, мінімальне і максимальне значення величин V_{mn} m -ї ознаки.

Обчислені на головному процесі оцінки V_{mn} разом з іншими необхідними параметрами відповідно до запропонованої вище моделі параметричного синтезу нейро-нечітких мереж у ярусно-паралельній формі передаються на інші процеси для паралельного формування початкової множини рішень $R^{(0)} = \{\chi_1^{(0)}, \chi_2^{(0)}, \dots, \chi_{N_\chi}^{(0)}\}$.

При побудові рішень $\chi_k^{(0)}$ будемо розширювати границі інтервалів $[c_{mn}; a_{mn}]$ і $[b_{mn}; d_{mn}]$, відповідно зменшуючи і збільшуючи значення параметрів c_{mn} і d_{mn} , у залежності від величин V_{mn} , що характеризують значущість n -го терму m -ї ознаки p_m . Збільшувати будемо ті інтервали, що відповідають високим значенням оцінок V_{mn} . З метою формування не єдиного рішення, а множини рішень у вигляді N_χ наборів параметрів нейро-нечітких моделей $R^{(0)} = \{\chi_1^{(0)}, \chi_2^{(0)}, \dots, \chi_{N_\chi}^{(0)}\}$ для забезпечення варіативності введемо коефіцієнт $\text{rand}[x; y]$ (випадково згенероване число в інтервалі від x до y), що забезпечує стохастичну складову при обчисленні параметрів c_{mn} і d_{mn} синтезованих нейро-нечітких моделей. Виходячи з вищесказаного значення параметрів c_{mn} і d_{mn} будемо розраховувати за формулами (5.19) і (5.20), відповідно:

$$c_{mn} = a_{mn} - \frac{P_{m \max} - P_{m \min}}{N_{\text{int}}} V_{mn} \text{rand}[1; 2], \quad (5.19)$$

$$d_{mn} = b_{mn} + \frac{P_{m \max} - P_{m \min}}{N_{\text{int}}} V_{mn} \text{rand}[1; 2]. \quad (5.20)$$

Наведені формули для обчислення значень c_{mn} і d_{mn} дозволяють згенерувати множину відповідних параметрів, кожний з яких залежить від оцінки значущості його терму Δp_{mn} і випадкового числа в інтервалі від 1 до 2, що забезпечує можливість максимального збільшення довжин інтервалів $[c_{mn}; a_{mn}]$ і $[b_{mn}; d_{mn}]$ до ширини двох інтервалів Δp_{mn} . Це також забезпечує можливість перетинання сусідніх інтервалів Δp_{mn-2} , Δp_{mn-1} , Δp_{mn} , Δp_{mn+1} , Δp_{mn+2} функцій належності $\mu_{mn}^{(1)}$, що у свою чергу забезпечує введення нечіткості на першому шарі синтезованої нейро-нечіткої мережі.

При необхідності забезпечення перетинання більшої кількості інтервалів Δp_{mn} і введення більшої нечіткості в приведених вище формулах можна збільшити значення другого параметра у функції $rand[x; y]$.

Для обчислення вагових коефіцієнтів $w_m^{(4,r)}$ четвертого шару синтезованої нейро-нечіткої мережі, що визначають значущість ознаки p_m в r -му правилі, будемо використовувати отримані раніше оцінки V_{mn} . Значущість ознаки p_m в r -му правилі $V_m(rule_r)$ визначається інформативністю $V_{mn, \Delta p_{mn} \in rule_r}$ відповідного терму Δp_{mn} m -ї ознаки в цьому правилі. Для забезпечення варіативності з метою формування множини рішень при обчисленні значень $w_m^{(4,r)}$ також будемо враховувати стохастичну складову $rand[x; y]$ (5.21):

$$w_m^{(4,r)} = \left(1 + V_{mn, \Delta p_{mn} \in rule_r} \right) rand[0;1]. \quad (5.21)$$

Таким чином, на кожному j -му вузлі ($j = 1, 2, \dots, N_{pr}$) паралельної системи відбувається формування підмножин $R^{(0,j)} = \left\{ \chi_1^{(0,j)}, \chi_2^{(0,j)}, \dots, \chi_{|R^{(0,j)}|}^{(0,j)} \right\}$

рішень, де параметри $g_{lk}^{(0,j)}$ рішення $\chi_k^{(0,j)} = \{g_{1k}^{(0,j)}, g_{2k}^{(0,j)}, \dots, g_{N_g k}^{(0,j)}\}$ обчислюються за формулами (5.19)–(5.21).

5.2.3 Оцінювання рішень

На наступному етапі виконується перетворення (5.22):

$$\chi_k^{(0,j)} \rightarrow NFN_k^{(0,j)}, \quad (5.22)$$

у результаті якого, використовуючи вирази (5.6)–(5.13), відбувається формування нейро-нечіткої мережі $NFN_k^{(0,j)}$ на основі заданої структури і набору параметрів, представлених у рішенні $\chi_k^{(0,j)}$.

Потім оцінюється якість розпізнавання для кожної k -ї згенерованої нейро-нечіткої моделі $NFN_k^{(0,j)}$: $G(NFN_k^{(0,j)})$. Дана оцінка обчислюється як помилка розпізнавання (у випадках, якщо вихід T у множини S є дискретним) або як середньоквадратична помилка (якщо вихід T приймає дійсні значення), що вимагає обчислення значень вихідного параметра $T_q(NFN_k^{(0,j)})$ за синтезованою моделлю $NFN_k^{(0,j)}$ для кожного q -го спостереження множини $S = \langle P, T \rangle$. Отримана в такий спосіб оцінка $G(NFN_k^{(0,j)})$ буде характеризувати пристосованість $G_k^{(0,j)}$ рішення $\chi_k^{(0,j)}$ у множині $R^{(0)}$: $G_k^{(0,j)} = G(\chi_k^{(0,j)}) = G(NFN_k^{(0,j)})$, що надалі дозволить відбирати найбільш пристосовані рішення для формування нових множин $R^{(i+1)}$.

5.2.4 Розбиття поточної множини рішень на підмножини

Після етапу оцінювання рішень виконується розбиття множини рішень $R^{(i)} = \{\chi_1^{(i)}, \chi_2^{(i)}, \dots, \chi_{N_\chi}^{(i)}\}$ на підмножини $R^{(i,j)}: R^{(i)} \rightarrow \{R^{(i,1)}, R^{(i,2)}, \dots, R^{(i,N_{pr})}\}$ з метою наступного пошуку екстремумів цільової функції $G^{(i)} = G(R^{(i)})$ в кожній j -й підмножині $R^{(i,j)}$ на j -му процесі паралельної системи. Формувати підмножини $R^{(i,j)}$ будемо таким чином, щоб кожен j -й набір являв собою групу компактно розташованих рішень $\chi_k^{(i)}$ у просторі елементів $\{g_1, g_2, \dots, g_{N_g}\}$. Це дозволить врахувати апріорну інформацію про просторове розташування рішень $\chi_k^{(i)}$ і більш детально досліджувати області розташування екстремальних рішень за допомогою випадкового пошуку. Оскільки обробку кожного набору $R^{(i,j)}$ пропонується здійснювати на відповідному процесі, загальна кількість формованих кластерів (підмножин $R^{(i,j)}$) відповідає кількості N_{pr} процесів паралельної системи.

Для визначення груп $R^{(i,j)}$ однотипних рішень $\chi_k^{(i)}$ будемо використовувати апріорну інформацію про початкове розташування параметрів g_{lk} , що налаштовуються (параметрів c_{mn} і d_{mn} функцій належності $\mu_{mn}^{(1)}$ нейроелементів першого шару і значень вагових $w_m^{(4,r)}$ коефіцієнтів нейронів четвертого шару). З приведених вище формул видно, що зазначені параметри розташовуються, як правило, в інтервалах $c_{mn} \in [a_{mn} - 2\Delta p_{mn}; a_{mn}]$, $d_{mn} \in [b_{mn}; b_{mn} + 2\Delta p_{mn}]$ (при $V_{mn} = 1$ та $rand[1;2] = 2$) і $w_m^{(4,r)} \in [0;2]$. Тому при формуванні розбиття $R^{(i)} \rightarrow \{R^{(i,1)}, R^{(i,2)}, \dots, R^{(i,N_{pr})}\}$ пропонується враховувати розташування рішень $\chi_k^{(i)}$ у відповідних інтервалах. Виконаємо розбиття кожного з наведених інтервалів на N_{pr} відрізків. Ранг $Rg(\chi_k^{(i)})$ рішення $\chi_k^{(i)}$ будемо оцінювати за формулою (5.23):

$$Rg(\chi_k^{(i)}) = \sum_{l=1}^{N_g} Rg(g_{lk}^{(i)}), \quad (5.23)$$

де $Rg(g_{lk}^{(i)})$ – ранг рішення $\chi_k^{(i)}$ по l -й ознаці – відповідає номеру інтервалу розбиття діапазону значень параметра g_l (в залежності від способу подання рішення $\chi_k^{(i)}$ параметр і діапазон його значень g_{lk} відповідає одній з трьох величин c_{mn} , d_{mn} , $w_m^{(4,r)}$), у який потрапило значення $g_{lk} \in [g_{lk \min}; g_{lk \max}]$. Величину $Rg(g_{lk}^{(i)})$ пропонується обчислювати за формулою (5.24):

$$Rg(g_{lk}^{(i)}) = 1 + N_{pr} \text{ceil} \left(\frac{g_{lk} - g_{l \min}}{g_{l \max} - g_{l \min}} \right), \quad (5.24)$$

де $\text{ceil}(A)$ – функція, що повертає цілу частину числа A .

Використання останньої формули дозволяє визначати ранги $Rg(g_{lk}^{(i)})$ таким чином, що вони відповідають номерам діапазонів розбиття інтервалу $g_l \in [g_{l \min}; g_{l \max}]$ на N_{pr} відрізків і можуть приймати значення $1, 2, \dots, N_{pr}$. Доцільність застосування такого підходу до оцінювання рішень $\chi_k^{(i)}$ (за допомогою рангів $Rg(\chi_k^{(i)})$) для їхнього розбиття на підмножини $R^{(i,j)}$ обумовлюється також відсутністю необхідності виконання обчислювально складних операцій сортування.

Набір $\{R^{(i,1)}, R^{(i,2)}, \dots, R^{(i,N_{pr})}\}$ формується в такий спосіб. До підмножини $R^{(i,1)}$ відносяться перші N_χ / N_{pr} за значеннями величини $Rg(\chi_k^{(i)})$ рішення $\chi_k^{(i)}$. Наступні N_χ / N_{pr} рішень утворюють підмножину $R^{(i,2)}$. Даний процес продовжується аналогічним чином для кожної підмножини $R^{(i,j)}$ доти, поки не буде сформована остання N_{pr} -а підмножина $R^{(i,N_{pr})}$.

Розбиття $R^{(i)} \rightarrow \{R^{(i,1)}, R^{(i,2)}, \dots, R^{(i,N_{pr})}\}$ також можна здійснити за допомогою модифікації методу нечітких c -середніх (FCM, Fuzzy c -means) [198], оскільки він передбачає можливість віднесення одного екземпляра (рішення $\chi_k^{(i)}$) до різних кластерів з різним ступенем належності, а також може бути використаний для побудови нейро-нечітких систем при визначенні нечітких множин. На відміну від базового методу нечітких c -середніх [198], у якому поточне розбиття на початковій ітерації одержують шляхом випадкової генерації елементів u_{kj} , що визначають належність k -го екземпляра j -му кластеру, у розробленому методі пропонується враховувати інформацію про розташування параметрів g_{lk} , що налаштовуються. Для визначення початкових значень величин u_{kj} обчислимо ранги $Rg(g_{lk}^{(i)})$ рішень $\chi_k^{(i)}$ по l -й ознаці, що відповідають номерам інтервалів розбиття діапазону значень параметра g_{lk} . Величину $Rg(g_{lk}^{(i)})$ пропонується обчислювати по наведеній вище формулі.

Для визначення початкових значень u_{kj} , що відповідають належності k -го екземпляра j -му кластеру, будемо використовувати формулу (5.25):

$$u_{kj} = \frac{N(Rg(g_{lk}^{(i)})=j)}{N_{pr}}, \quad (5.25)$$

де $N(Rg(g_{lk}^{(i)})=j)$ – кількість рангів $Rg(g_{lk}^{(i)})$, що дорівнюють j . Формула (5.25)

забезпечує виконання умови $\sum_{k=1}^{N_{\chi}} u_{kj} = 1$.

Далі для кожного j -го кластера визначається його центр $C_j = \{C_{1j}, C_{2j}, \dots, C_{N_g j}\}$, де C_{lj} – l -та координата центра j -го кластера, що обчислюється за формулою (5.26):

$$C_{lj} = \frac{\sum_{k=1}^{N_\chi} (u_{kj})^{mp} g_{jk}}{\sum_{k=1}^{N_\chi} (u_{kj})^{mp}}, \quad (5.26)$$

де mp – параметр методу, як правило, $mp = 2$.

Потім обчислюється значення функції $J(R^{(i)}, u^{(i)}, C^{(i)})$ (5.27), що характеризує якість нечіткого розбиття:

$$J(R^{(i)}, u^{(i)}, C^{(i)}) = \sum_{k=1}^{N_\chi} \sum_{j=1}^{N_{pr}} (u_{kj})^{mp} D^2(\chi_k^{(i)}, C_j), \quad (5.27)$$

де $D(\chi_k^{(i)}, C_j)$ – відстань між рішенням $\chi_k^{(i)}$ і центром C_j j -го кластера. Як правило, дана відстань обчислюється за допомогою Евклідової метрики (5.28):

$$D(\chi_k^{(i)}, C_j) = \sqrt{\sum_{l=1}^{N_g} (g_{lk}^{(i)} - C_{lj})^2}. \quad (5.28)$$

Після цього формується нове нечітке розбиття шляхом перерахування значень u_{kj} , використовуючи формулу (5.29):

$$u_{kj} = \left(\sum_{t=1}^{N_{pr}} \left(\frac{D(\chi_k^{(i)}, C_j)}{D(\chi_k^{(i)}, C_t)} \right)^{\frac{2}{mp-1}} \right)^{-1}. \quad (5.29)$$

При цьому, якщо $D(\chi_k^{(i)}, C_j) = 0$, то $\chi_k^{(i)}$ є центром j -го кластера, то встановлюються такі значення параметрів u_{kj} : $u_{kj} = 1$, для всіх інших кластерів: $u_{k'j} = 0, k' \neq k$. Потім для отриманого нечіткого розбиття u_{kj} ($k = 1, 2, \dots, N_\chi$,

$j=1,2,\dots,N_{pr}$) використовуючи формули (5.26)–(5.28) розраховуються нові центри нечітких кластерів $C_j = \{C_{1j}, C_{2j}, \dots, C_{N_g j}\}$ і значення критерію $J(R^{(i)}, u^{(i)}, C^{(i)})$. Процес продовжується доти, поки кількість ітерацій не перевищить максимально припустиму чи поки зміна значення критерію $J(R^{(i)}, u^{(i)}, C^{(i)})$ носить істотний характер (5.30):

$$\left| J_{old}(R^{(i)}, u^{(i)}, C^{(i)}) - J(R^{(i)}, u^{(i)}, C^{(i)}) \right| \leq \varepsilon_J, \quad (5.30)$$

де $J_{old}(R^{(i)}, u^{(i)}, C^{(i)})$ та $J(R^{(i)}, u^{(i)}, C^{(i)})$ – значення критерію якості розбиття J на попередній і поточній ітераціях, відповідно;

ε_J – мінімально прийнятна зміна значення критерію J .

Після одержання прийнятних значень величин u_{kj} , що характеризують належність k -го екземпляра $\chi_k^{(i)}$ j -му кластеру виконується формування підмножин $R^{(i,j)}$ ($j=1,2,\dots,N_{pr}$). При цьому пропонується враховувати як значення належності u_{kj} до кожного з кластерів $R^{(i,j)}$, так і значення цільової функції $G_k^{(i)} = G(\chi_k^{(i)})$. Це дозволить підвищити імовірність відбору при формуванні підмножин $R^{(i,j)}$ таких рішень $\chi_k^{(i)}$, що геометрично відповідають j -му кластеру (просторово розташовані близько до його центра) і характеризуються при цьому прийнятною пристосованістю $G_k^{(i)}$. Рішення $\chi_k^{(i)}$ будемо вносити в підмножину $R^{(i,j)}$ ($R^{(i,j)} = R^{(i,j)} \cup \chi_k^{(i)}$) при виконанні умови (5.31):

$$G_k^{(i)} + u_{kj} \leq \text{rand}[0; 2]. \quad (5.31)$$

Перегляд множини $R^{(i)}$ продовжується і повторюється доти, поки не будуть послідовно сформовані всі підмножини $R^{(i,j)}$, кожна з яких складається з N_χ / N_{pr} рішень.

5.2.5 Пошук оптимальних рішень на основі паралельного підходу

Після розбиття на головному процесі множини $R^{(i)}$ на підмножини $\{R^{(i,1)}, R^{(i,2)}, \dots, R^{(i,N_{pr})}\}$ виконується їхня передача на інші процеси для паралельного випадкового пошуку екстремумів.

Як відзначено вище, основними етапами випадкового пошуку є формування нової множини рішень, оцінювання якості нових рішень і перевірка критеріїв зупинення.

Для формування нового набору $R^{(i',j)}$ на j -му процесі будемо відбирати рішення $\chi_k^{(i,j)} \in R^{(i,j)}$, виходячи зі значень їхньої цільової функції $G_k^{(i,j)} = G(\chi_k^{(i,j)})$. Рішення $\chi_k^{(i,j)} \in R^{(i,j)}$ пропонується вводити в набір рішень $R_{selected}^{(i,j)}$, допущених для формування нового покоління $R^{(i',j)}$ при виконанні умови (5.32):

$$G_{k,norm}^{(i,j)} \leq rand[0;1], \quad (5.32)$$

де $G_{k,norm}^{(i,j)}$ – нормоване значення цільової функції $G_k^{(i,j)}$ для множини $R^{(i,j)}$.

Таким чином, чим меншою є помилка $G_k^{(i,j)}$ синтезованої мережі $NFN_k^{(i,j)} = NFN(\chi_k^{(i,j)})$, тим вищою є ймовірність рішення $\chi_k^{(i,j)} \in R^{(i,j)}$ бути відібраним для формування нової множини $R^{(i',j)}$.

Крім описаного вище підходу можна в приведену формулу ввести множник $\frac{N(w_m^{(4,r)} \approx 0)}{M \cdot N_R}$, що враховує кількість значень вагових коефіцієнтів $w_m^{(4,r)}$, близьких до нуля, що дозволить зменшити кількість зв'язків у синтезованій нейро-нечіткої моделі, спростивши в такий спосіб її структуру і зробивши її більш зрозумілою (інтерпретованою) для сприйняття й аналізу.

Нову множину рішень $R^{(i',j)}$ аналогічно еволюційному підходу до пошуку оптимальних рішень [204–211, 267–269, 299] пропонується формувати з найбільш пристосованих (елітних) наборів $\chi_k^{(i,j)}$, а також наборів, отриманих у результаті застосування еволюційних операторів схрещування та мутації. Кількість рішень нового покоління, одержуваних тим чи іншим шляхом, визначається з округленням до цілого числа по формулах (5.33):

$$N_{elite} = \alpha N_\chi, \quad N_{cross} = \beta N_\chi, \quad N_{mutation} = \gamma N_\chi, \quad (5.33)$$

де $N_{elite} = \alpha N_\chi$ – кількість елітних рішень (рішень $\chi_k^{(i,j)} \in R^{(i,j)}$ з найкращими значеннями оцінок $G_k^{(i,j)}$ у множини $R^{(i,j)}$);

$N_{cross} = \beta N_\chi$ – кількість рішень, одержуваних у результаті застосування оператора схрещування;

$N_{mutation} = \gamma N_\chi$ – кількість рішень, генерованих за допомогою оператора мутації;

α, β, γ – коефіцієнти, що визначають значущість того чи іншого способу одержання нового набору, $\alpha + \beta + \gamma = 1$.

Пропонується за замовчуванням установлювати такі значення цих коефіцієнтів: $\alpha = 0,05$, $\beta = 0,8$, $\gamma = 0,15$, що дозволяє при переході на наступну ітерацію не втрачати найбільш пристосовані рішення (у множині $R^{(i',j)}$ при $\alpha = 0,05$ переходить 5 % рішень $\chi_k^{(i,j)}$ з найкращими оцінками $G_k^{(i,j)}$),

генерувати більшість рішень нової множини на основі декількох рішень за допомогою оператора схрещування (80 % нових рішень створюється шляхом застосування оператора схрещування), а також забезпечувати можливість виходу з локальних екстремумів шляхом застосування оператора мутації (15 % рішень для $R^{(i',j)}$ формується за допомогою мутації).

При формуванні нової множини N_{cross} рішень створюються за допомогою схрещування наборів, представлених у множині $R_{selected}^{(i,j)}$. Елементи $g_{lk}^{(i')}$ нового рішення $\chi_k^{(i',j)}$ на основі рішень-батьків $\chi_{p1}^{(i,j)} \in R_{selected}^{(i,j)}$ та $\chi_{p2}^{(i,j)} \in R_{selected}^{(i,j)}$ можуть визначатися за формулами (5.34)–(5.37):

$$g_{lk}^{(i')} = \eta g_{l,p1}^{(i)} + (1 - \eta) g_{l,p2}^{(i)}, \quad (5.34)$$

$$g_{lk}^{(i')} = \max(g_{l,p1}^{(i)}, g_{l,p2}^{(i)}) - \eta (\max(g_{l,p1}^{(i)}, g_{l,p2}^{(i)}) - g_{lmin}) = \eta g_{lmin} + (1 - \eta) \max(g_{l,p1}^{(i)}, g_{l,p2}^{(i)}), \quad (5.35)$$

$$g_{lk}^{(i')} = \min(g_{l,p1}^{(i)}, g_{l,p2}^{(i)}) + \eta (g_{lmax} - \min(g_{l,p1}^{(i)}, g_{l,p2}^{(i)})) = \eta g_{lmax} + (1 - \eta) \min(g_{l,p1}^{(i)}, g_{l,p2}^{(i)}), \quad (5.36)$$

$$g_{lk}^{(i')} = \frac{1}{2} \left((1 - \eta) (g_{lmin} + g_{lmax}) + \eta (g_{l,p1}^{(i)} + g_{l,p2}^{(i)}) \right), \quad (5.37)$$

де $g_{l,p1}^{(i)}$ та $g_{l,p2}^{(i)}$ – значення l -х елементів рішень-батьків $\chi_{p1}^{(i,j)} \in R_{selected}^{(i,j)}$ та $\chi_{p2}^{(i,j)} \in R_{selected}^{(i,j)}$, відповідно;

g_{lmin} та g_{lmax} – мінімальне та максимальне значення l -х елементів, відповідно;

$\eta \in [0;1]$ – коефіцієнт, що може бути отриманий випадковим чином ($\eta = rand[0;1]$) чи розрахований у залежності від значень цільової функції $G_k^{(i,j)}$ батьків $\chi_{p1}^{(i,j)}$ і $\chi_{p2}^{(i,j)}$ таким чином, щоб підсилити вплив рішення з кращим (меншим) значенням $G_k^{(i,j)}$ (5.38):

$$\eta = \begin{cases} \text{rand}[0,5;1], & G_{p1}^{(i,j)} < G_{p2}^{(i,j)}; \\ 1 - \text{rand}[0;0,5], & G_{p1}^{(i,j)} \geq G_{p2}^{(i,j)}. \end{cases} \quad (5.38)$$

При цьому останній вираз доцільно застосовувати при формуванні нових рішень за допомогою формули (5.34), а випадкове генерування коефіцієнта $\eta = \text{rand}[0;1]$ має сенс використовувати у випадку застосування формул (5.35)–(5.37). Використання формул (5.34)–(5.38) у запропонованому операторі схрещування дозволяє створювати нові рішення $\chi_k^{(i',j)}$ з урахуванням особливостей параметрів g_{lk} , що налаштовуються (діапазону їхніх значень), і пристосованості $\chi_{p1}^{(i,j)} \in R_{selected}^{(i,j)}$ рішень-батьків $\chi_{p2}^{(i,j)} \in R_{selected}^{(i,j)}$.

Як відзначено вище, у нову множину $R^{(i',j)}$ потрапляє $N_{mutation} = \gamma N_\chi$ рішень за допомогою оператора мутації. Мутації будемо проводити над обраними рішеннями $\chi_{mutated}^{(i,j)} \in R_{selected}^{(i,j)}$ таким чином, щоб змінювати значення деяких елементів $g_{lk,mutated}^{(i)} \in \chi_{mutated}^{(i,j)}$ у межах деякого діапазону. Кількість $N_{g,mutated}$ мутуючих параметрів $g_{lk,mutated}^{(i)}$ визначається в такий спосіб: $N_{g,mutated} = \vartheta N_g$, де ϑ – частка параметрів $g_{lk}^{(i)}$, що піддається мутації в обраних рішеннях $\chi_{mutated}^{(i,j)} \in R_{selected}^{(i,j)}$, за замовчуванням частку ϑ мутуючих параметрів $g_{lk,mutated}^{(i)}$ пропонується установити на рівні 10 %, що дозволить забезпечити зміну значень кожного десятого параметра, що налаштовуються. Зміну значень $g_{lk}^{(i)}$ пропонується виконувати, використовуючи вираз (5.39):

$$g_{lk}^{(i')} = \begin{cases} \text{rand}[g_{l \min}; g_{l \max}], & G_{mutated}^{(i,j)} \geq G_{mean}^{(i,j)}; \\ \text{rand}[g_{l \min} - \Delta g_l; g_{l \max}], & G_{mutated}^{(i,j)} < G_{mean}^{(i,j)}, g_l \rightarrow c_{mn}; \\ \text{rand}[g_{l \min}; g_{l \max} + \Delta g_l], & G_{mutated}^{(i,j)} < G_{mean}^{(i,j)}, g_l \rightarrow d_{mn}; \\ \text{rand}[0; g_{lk}^{(i)}], & G_{mutated}^{(i,j)} < G_{mean}^{(i,j)}, g_l \rightarrow w_m^{(4,r)}, \end{cases} \quad (5.39)$$

де $\Delta g_l = g_{l \max} - g_{l \min}$ – ширина діапазону зміни l -х елементів g_l ;

$G_{mean}^{(i,j)}$ – середнє значення цільової функції $G_k^{(i,j)}$ в множини $R^{(i,j)}$.

Позначення $g_l \rightarrow c_{mn}$, $g_l \rightarrow d_{mn}$, $g_l \rightarrow w_m^{(4,r)}$ відображають тип параметра, що налаштовується, в елементі g_l : c_{mn} , d_{mn} , $w_m^{(4,r)}$, відповідно.

Застосування виразу (5.39) дозволяє генерувати значення мутуючих параметрів $g_{lk,mutated}^{(i)}$ як випадкові числа з відповідних діапазонів $[g_{l \min}; g_{l \max}]$ у випадку, якщо значення цільової функції $G_{mutated}^{(i,j)}$ не перевищує середнього значення $G_k^{(i,j)}$ в множини $R^{(i,j)}$. У протилежному випадку враховуються не тільки особливості розташування (діапазон значень) параметрів g_{lk} , що налаштовуються, але і їхній тип (параметри c_{mn} , d_{mn} функцій належності нейронів першого шару, вагові коефіцієнти $w_m^{(4,r)}$ нейроелементів на четвертому шарі); допускається вихід за межі відповідних діапазонів, що дозволяє розширювати область пошуку і виходити з можливих областей локальних екстремумів, а також забезпечується зменшення деяких значень вагових коефіцієнтів четвертого шару $w_m^{(4,r)} = rand[0; g_{lk}^{(i)}]$ для можливості наступного обнуління таких ваг і, відповідно, спрощення структури синтезованої нейро-нечіткої моделі.

Після створення нових наборів рішень $R^{(i',j)} = \left\{ \chi_1^{(i',j)}, \chi_2^{(i',j)}, \dots, \chi_{|R^{(i',j)}|}^{(i',j)} \right\}$

виконуються перетворення вигляду (5.22) $\chi_k^{(i',j)} \rightarrow NFN_k^{(i',j)}$ і оцінювання кожного з рішень $\chi_k^{(i',j)}$: $G_k^{(i',j)} = G(\chi_k^{(i',j)}) = G(NFN_k^{(i',j)})$.

Потім перевіряються критерії зупинення (досягнення максимальної кількості ітерацій N_{it} на кожному j -му процесі, отримання прийняттого значення G_{ac} цільової функції $\min(G_k^{(i)}) \leq G_{ac}$ та ін.). У випадку незадоволення зазначених критеріїв виконується формування множини $R^{(i'',j)}$.

З метою внесення деякої розмаїтості в популяції $R^{(i,j)}$ з деякою періодичністю L_{migr} виконуються міграції рішень $\chi_k^{(i,j)}$ у сусідні популяції $R^{(i,j')}$, $j' \neq j$. Кожен j -й процес передає в широкомовному режимі $N_{elite} = \alpha N_\chi$ найбільш пристосовані рішення $\chi_{k,elite}^{(i,j)}$ з обчисленими значеннями їхніх цільових функцій $G_{k,elite}^{(i,j)} = G(\chi_{k,elite}^{(i,j)})$, а також приймає аналогічні рішення $\chi_{k,elite}^{(i,j')}$ і $G_{k,elite}^{(i,j')}$ від інших процесів $j' \neq j$. Таким чином, на кожному j -му процесі формується множина $R_{migrated}^{(i,j)}$ мігрованих рішень $\chi_{k,migrated}^{(i,j)} \in R_{migrated}^{(i,j)}$. У підпопуляцію $R^{(i',j)}$ пропонується вводити $N_{elite} = \alpha N_\chi$ рішень з $R_{migrated}^{(i,j)}$. Вибір рішень $\chi_{k,migrated}^{(i,j)} \in R_{migrated}^{(i,j)}$ для їхнього додавання в $R^{(i',j)}$ пропонується здійснювати пропорційно значенням цільових функцій $G_{k,migrated}^{(i,j)} = G(\chi_{k,migrated}^{(i,j)})$: якщо виконується умова $G_{k,migrated,norm}^{(i,j)} \leq rand[0;1]$, то рішення $\chi_{k,migrated}^{(i,j)} \in R_{migrated}^{(i,j)}$ додається в підмножину $R^{(i',j)}$, де $G_{k,migrated,norm}^{(i,j)}$ – нормоване значення цільової функції $G_{k,migrated}^{(i,j)}$ рішення $\chi_{k,migrated}^{(i,j)}$. При цьому з метою забезпечення виконання умови $\alpha + \beta + \gamma = 1$, що дозволяє не змінювати загальну кількість рішень N_χ / N_{pr} на кожному j -му процесі (у кожній підмножині $R^{(i,j)}$), на ітераціях випадкового пошуку, що передбачають передачу деяких рішень іншим процесам, необхідно зменшити значення суми коефіцієнтів β і γ на величину α : $(\beta + \gamma)_{migrated} = (\beta + \gamma) - \alpha$, зменшуючи в такий спосіб кількість нащадків, згенерованих шляхом застосування схрещування і мутації.

Міграції не повинні бути занадто частими, щоб не вироджувалася кожна j -а підпопуляція $R^{(i,j)}$ (забезпечувався пошук у різних областях простору $\{g_1, g_2, \dots, g_{N_g}\}$) і час, затрачуваний на пересилання, не був занадто великим. Тому пропонується міграції рішень проводити ζ разів (за замовчуванням пропонується $\zeta = 3$): через кожні $\text{ceil}\left(\frac{1}{\zeta+1} N_{it}\right)$ ітерацій, забезпечуючи в такий

спосіб обмін найкращими рішеннями на $\text{ceil}\left(\frac{1}{\zeta+1}N_{it}\right)$, $\text{ceil}\left(\frac{2}{\zeta+1}N_{it}\right)$, ..., $\text{ceil}\left(\frac{\zeta}{\zeta+1}N_{it}\right)$ ітераціях випадкового пошуку. Цей процес дозволить вносити розмаїтість у підпопуляції, забезпечувати можливість виходу з локальних екстремумів, переміщуючись в області розташування інших локальних оптимумів.

Після виконання N_{it} ітерацій пошуку $RS(R^{(i,j)})$ в кожній з N_{pr} підмножин $R^{(i,j)}$ виконується їхнє об'єднання в єдину популяцію $R^{(i')} = R^{(i',1)} \cup R^{(i',2)} \cup \dots \cup R^{(i',N_{pr})}$. Для цього відповідно до запропонованої моделі параметричного синтезу нейро-нечітких мереж у ярусно-паралельній формі (рис. 5.1) виконується пересилання на головний процес наборів значень $\langle R^{(i',j)}, G^{(i',j)} \rangle$, $R^{(i',j)} = \left\{ \chi_1^{(i',j)}, \chi_2^{(i',j)}, \dots, \chi_{|R^{(i',j)}|}^{(i',j)} \right\}$, $G^{(i',j)} = \left\{ G_1^{(i',j)}, G_2^{(i',j)}, \dots, G_{|R^{(i',j)}|}^{(i',j)} \right\}$, $j = 1, 2, \dots, N_{pr}$. Потім відбувається випадковий пошук $RS(R^{(i')})$ над об'єднаною популяцією $R^{(i')}$ з обчисленням значень цільових функцій на різних процесах паралельної системи. Такий пошук дозволить досліджувати простір пошуку без розбиття його на деякі ділянки і виявляти нові екстремальні області, що містять субоптимальні рішення. Формування нових рішень при цьому пропонується здійснювати за допомогою операторів відбору, схрещування та мутації, що наведені вище. Для скорочення часу ймовірнісної оптимізації визначення значень цільових функцій $G_k^{(i')} = G(\chi_k^{(i')}) = G(NFN_k^{(i')})$, як обчислювально складний процес, пропонується виконувати на різних вузлах паралельної системи.

Після виконання випадкового пошуку $RS(R^{(i')})$ у випадку незадоволення критеріїв зупинення знову виконується розбиття множини $R^{(i')}$ на підмножини $R^{(i')} \rightarrow \left\{ R^{(i',1)}, R^{(i',2)}, \dots, R^{(i',N_{pr})} \right\}$ з наступним пошуком $RS(R^{(i',j)})$

оптимальних рішень у кожній з них. Процеси $RS(R^{(i,j)})$, $j = 1, 2, \dots, N_{pr}$ та $RS(R^{(i)})$ виконуються, змінюючи один одного, до задоволення критеріїв закінчення пошуку.

Таким чином, запропонований метод параметричної ідентифікації нейро-нечітких моделей на основі паралельного випадкового пошуку використовує ймовірнісну оптимізацію для настроювання параметрів синтезованих нейромереж (параметри функцій належності і вагові коефіцієнти нейроелементів).

На відміну від відомих методів випадкового пошуку, початкова множина рішень формується з урахуванням апріорної інформації про навчальну вибірку (враховується значущість термів ознак, використовуючи щільність розташування екземплярів навчальної множини у відповідному термі та ступінь його впливу на значення вихідного параметра), що дозволяє наблизити початкові точки пошуку до областей розташування екстремумів і прискорити процес оптимізації.

З метою більш детального дослідження областей локальних оптимумів у запропонованому методі виконується розбиття поточної множини рішень на підмножини з наступним пошуком оптимумів у кожній з них на відповідних процесах паралельної системи. При цьому формування відповідних підмножин відбувається таким чином, щоб кожен набір являв собою групу компактно розташованих рішень у просторі елементів, які налаштовуються, що дозволяє враховувати інформацію про просторове розташування рішень і більш детально досліджувати області розташування екстремальних рішень за допомогою випадкового пошуку.

Випадковий пошук над об'єднаною популяцією в запропонованому методі дозволяє досліджувати простір пошуку без розбиття його на деякі ділянки та виявляти нові екстремальні області, що містять субоптимальні рішення. Визначення значень цільових функцій, як обчислювально складний

процес, пропонується виконувати на різних вузлах паралельної системи, що дозволяє скоротити час імовірнісної оптимізації.

У запропонованих операторах схрещування та мутації при формуванні нової множини рішень враховуються особливості розташування (діапазон значень) параметрів, що налаштовуються, їхній тип (параметри функцій належності нейронів, вагові коефіцієнти нейроелементів), пристосованість рішень-батьків, а також допускається вихід за межі відповідних діапазонів, що дозволяє розширювати область пошуку і виходити з можливих областей локальних екстремумів.

5.3 Аналіз обчислювальної складності й оцінювання ефективності паралельної системи

Для оцінювання обчислювальної складності розробленого методу параметричного синтезу нейро-нечітких мереж визначимо складність O кожного з його етапів, де O – оператор Ландау «о велике», що характеризує кількість елементарних операцій, необхідних для розв'язання деякої задачі. Будемо вважати, що всі операції є рівноцінними по обчислювальній складності.

На етапі ініціалізації виконується розбиття значень кожної ознаки p_m ($m = 1, 2, \dots, M$) множини спостережень $S = \langle P, T \rangle$ на N_{int} інтервалів $\Delta p_{mn} = [p_{mn \text{ min}}; p_{mn \text{ max}}]$ ($n = 1, 2, \dots, N_{\text{int}}$), обчислюється значущість V_{mn} кожного терму Δp_{mn} , що вимагає визначення ентропії $\text{Entr}(\Delta p_{mn})$ кожного інтервалу Δp_{mn} та ймовірностей ρ_q . Тому обчислювальна складність даного процесу [332] може бути визначена виходячи з виразу (5.40):

$$O(V_{\text{init}}) = O(MN_{\text{int}} + MN_{\text{int}} N_{\text{int}T}) = O(MN_{\text{int}} N_{\text{int}T}), \quad (5.40)$$

де N_{intT} – кількість інтервалів розбиття (класів) вихідного параметра T множини S .

Крім того, з використанням запропонованих формул відбувається ініціалізація (обчислення) значень c_{mn} , d_{mn} і $w_m^{(4,r)}$ ($m = 1, 2, \dots, M$, $n = 1, 2, \dots, N_{int}$, $r = 1, 2, \dots, N_R$) для кожного рішення $\chi_k^{(0)}$ ($k = 1, 2, \dots, N_\chi$) у множині $R^{(0)} = \{\chi_1^{(0)}, \chi_2^{(0)}, \dots, \chi_{N_\chi}^{(0)}\}$. Кількість елементарних операцій, необхідних для розв'язання цієї задачі, можна визначити в такий спосіб (5.41):

$$O(\chi_{init}) = O(N_\chi (MN_{int} + MN_{int} + MN_R)) = O(N_\chi M (N_{int} + N_R)). \quad (5.41)$$

Обчислення значень цільових функцій $G_k^{(0)} = G(\chi_k^{(0)}) = G(NFN_k^{(0)})$ виконується на N_{pr} паралельних процесах для кожного з N_χ / N_{pr} рішення $\chi_k^{(0)}$. Визначення оцінок $G_k^{(0)}$ пов'язано з необхідністю перетворення $\chi_k^{(0)} \rightarrow NFN_k^{(0)}$, що передбачає використання виразів (5.6)–(5.13) і необхідності оброблення кожного спостереження в множині $S = \langle P, T \rangle$. Обчислювальну складність $O(G)$ цього процесу визначимо по формулі (5.42):

$$O(G) = O\left(\frac{N_\chi}{N_{pr}} N_{pr} (MN_{int} + N_R + N_R + MN_R + N_R) Q\right) = O(N_\chi M Q (N_{int} + N_R)). \quad (5.42)$$

При виконанні перетворення $R^{(i)} \rightarrow \{R^{(i,1)}, R^{(i,2)}, \dots, R^{(i,N_{pr})}\}$ відбувається розбиття інтервалів можливих значень кожного з N_g параметрів, що налаштовуються (c_{mn} , d_{mn} , $w_m^{(4,r)}$ і N_{pr}), на N_χ відрізків для кожного з $\chi_k^{(0)}$ рішень. Кількість операцій, необхідних для виконання перетворення $R^{(i)} \rightarrow \{R^{(i,1)}, R^{(i,2)}, \dots, R^{(i,N_{pr})}\}$ оцінимо в такий спосіб (5.43):

$$O(R_{init}) = O(N_g N_\chi). \quad (5.43)$$

Як видно, найбільш складною задачею є обчислення значень цільових функцій (оцінка $O(G)$ пропорційна добутку величин $N_\chi MQ(N_{int} + N_R)$), що обумовило доцільність розпаралелювання даного процесу.

З огляду на вирази (5.40)–(5.43), а також те, що $N_{intT} \ll Q$ (кількість інтервалів розбиття вихідного параметра T у множини $S = \langle P, T \rangle$ є значно меншим, ніж загальна кількість спостережень Q у цій же множини) і $N_g \ll MQ$ (кількість параметрів моделі, що налаштовуються, є істотно меншою, ніж загальна кількість елементів множини S), загальна складність O_{init} етапу ініціалізації може бути оцінена по формулі (5.44):

$$O_{init} = O(V_{init}) + O(\chi_{init}) + O(G) + O(R_{init}) = O(MN_{int}N_{intT} + N_\chi M(N_{int} + N_R) + N_\chi MQ(N_{int} + N_R) + N_g N_\chi) = O(N_\chi MQ(N_{int} + N_R)). \quad (5.44)$$

Виконання процесів випадкового пошуку $RS(R^{(i,j)})$ пов'язано з необхідністю обробки множин, що складаються з N_χ / N_{pr} рішень, на кожному з N_{pr} процесів (необхідно виконувати відбір рішень, їхнє схрещування, мутацію й обчислювати значення цільової функції). Оцінки обчислювальної складності кожного з зазначених процесів можуть бути розраховані по формулах (5.45), (5.46), (5.47) і (5.42), відповідно:

$$O(RS_{select}^{(i,j)}) = O\left(\frac{N_\chi}{N_{pr}} N_{pr}\right) = O(N_\chi). \quad (5.45)$$

$$O(RS_{cross}^{(i,j)}) = O\left(\beta \frac{N_\chi}{N_{pr}} N_g N_{pr}\right) = O(\beta N_\chi N_g). \quad (5.46)$$

$$O(RS_{mutation}^{(i,j)}) = O\left(\gamma\vartheta \frac{N_\chi}{N_{pr}} N_g N_{pr}\right) = O(\gamma\vartheta N_\chi N_g), \quad (5.47)$$

$\beta + \gamma < 1, \vartheta < 1.$

Отже, оцінка обчислювальної складності процесу $RS(R^{(i,j)})$ при N_{it} ітерацій може бути визначена в такий спосіб (5.48):

$$\begin{aligned} O(RS^{(i,j)}) &= O\left(N_{it}\left(N_\chi + \beta N_\chi N_g + \gamma\vartheta N_\chi N_g + N_\chi MQ(N_{int} + N_R)\right)\right) = \\ &= O\left(N_{it} N_\chi MQ(N_{int} + N_R)\right). \end{aligned} \quad (5.48)$$

Кількість операцій, необхідних для виконання випадкового пошуку $RS(R^{(i)})$ над узагальненою популяцією $R^{(i)}$ з урахуванням того, що обчислення значень цільової функції відбувається на паралельних процесах, визначається аналогічно (5.49):

$$\begin{aligned} O(RS^{(i)}) &= O\left(N_{it}\left(N_\chi + \beta N_\chi N_g + \gamma\vartheta N_\chi N_g + N_\chi MQ(N_{int} + N_R)\right)\right) = \\ &= O\left(N_{it} N_\chi MQ(N_{int} + N_R)\right). \end{aligned} \quad (5.49)$$

Оскільки у випадку незадоволення критеріїв зупинення процесу $RS(R^{(i,j)})$ і $RS(R^{(i)})$ поперемінно виконуються (будемо вважати, що дані процеси можуть повторюватися також не більш ніж N_{it} ітерацій) до задоволення критеріїв закінчення пошуку, загальну оцінку обчислювальної складності запропонованого методу визначимо по формулі (5.50):

$$O = O_{init} + N_{it}\left(O(RS^{(i,j)}) + O(RS^{(i)})\right). \quad (5.50)$$

Оцінимо максимально можливе прискорення $Speedup_{pr}$ та ефективність паралельної системи $Efficiency_{pr}$ при використанні запропонованого методу параметричного синтезу нейро-нечітких моделей на N_{pr} процесах паралельної системи.

Нехай α_{serial} – частка обчислень, що приходяться на послідовні етапи методу. Частку послідовних операцій методу α_{serial} визначимо по формулі (5.51):

$$\alpha_{serial} = \frac{N_{serial}}{N_{serial} + N_{paral}} = \frac{1}{1 + \frac{N_{paral}}{N_{serial}}}, \quad (5.51)$$

де N_{serial} – кількість операцій, що виконуються послідовно;

N_{paral} – кількість операцій, що виконуються на паралельних процесах.

Як оцінки величин N_{serial} і N_{paral} будемо використовувати оцінки обчислювальної складності різних операцій запропонованого методу, знайдені раніше, використовуючи вирази (5.40)–(5.50).

Відповідно до запропонованої моделі параметричного синтезу нейро-нечітких мереж у ярусно-паралельній формі послідовно виконуються деякі операції на етапі ініціалізації (обчислювальна складність таких операцій відповідно до наведених вище формул оцінюється як $O(V_{init})$, $O(\chi_{init})$, $O(R_{init})$), а також операції, пов'язані з формуванням нової множини рішень (відбір, схрещування та мутація) при випадковому пошуку $RS(R^{(i)})$ (обчислювальна складність таких операцій: $N_{it}(O(RS_{select}^{(i)}) + O(RS_{cross}^{(i)}) + O(RS_{mutation}^{(i)}))$). Тому порядок оцінки величини N_{serial} визначимо так (5.52):

$$N_{serial} \sim O(V_{init}) + O(\chi_{init}) + O(R_{init}) + N_{it}(O(RS_{select}^{(i)}) + O(RS_{cross}^{(i)}) + O(RS_{mutation}^{(i)})). \quad (5.52)$$

Паралельно на етапі ініціалізації виконуються операції, пов'язані з обчисленням значень цільової функції ($O(G) = O(N_\chi MQ(N_{int} + N_R))$), операції процесів випадкового пошуку $RS(R^{(i,j)})$ (обчислювальна складність $O(RS^{(i,j)}) = O(N_{it}(N_\chi + \beta N_\chi N_g + \gamma \vartheta N_\chi N_g + N_\chi MQ(N_{int} + N_R)))$), а також операції обчислення цільової функції G при пошуку $RS(R^{(i)})$ (обчислювальна складність $O(RS_G^{(i)}) = O(N_{it} N_\chi MQ(N_{int} + N_R))$). Тому порядок величини N_{paral} оцінимо в такий спосіб (5.53):

$$N_{paral} \sim O(G) + N_{it} (O(RS^{(i,j)}) + O(RS_G^{(i)})) = O(N_\chi MQ(N_{int} + N_R)) + N_{it} O(N_\chi (N_\chi + \beta N_\chi N_g + \gamma \vartheta N_\chi N_g + N_\chi MQ(N_{int} + N_R))) + N_{it} (N_\chi MQ(N_{int} + N_R)) \quad (5.53)$$

Як відзначено вище, оцінки $O(V_{init})$, $O(\chi_{init})$, $O(R_{init})$, а, отже, і їхня сума $O(V_{init}) + O(\chi_{init}) + O(R_{init})$, є істотно нижчими, ніж оцінки $O(G) = O(N_\chi MQ(N_{int} + N_R))$. Підставляючи (5.52) та (5.53) у (5.51), одержуємо оцінку (5.54) частки обчислень α_{serial} , що приходяться на послідовні етапи методу:

$$\begin{aligned} \alpha_{serial} &\sim \frac{1}{N_{it} (O(RS^{(i,j)}) + O(RS_G^{(i)}))} = \\ &= \frac{1}{1 + \frac{N_{it} (O(RS_{select}^{(i)}) + O(RS_{cross}^{(i)}) + O(RS_{mutation}^{(i)}))}{N_{it} (O(RS^{(i,j)}) + O(RS_G^{(i)}))}} = \\ &= \frac{1}{1 + \frac{O(N_{it} (N_\chi + \beta N_\chi N_g + \gamma \vartheta N_\chi N_g + N_\chi MQ(N_{int} + N_R))) + N_{it} (N_\chi MQ(N_{int} + N_R))}{O(N_\chi) + O(\beta N_\chi N_g) + O(\gamma \vartheta N_\chi N_g)}} = \\ &= \frac{1}{1 + \frac{N_{it} N_\chi O(1 + \beta N_g + \gamma \vartheta N_g + 2MQ(N_{int} + N_R))}{N_\chi O(1 + \beta N_g + \gamma \vartheta N_g)}} = \\ &= \frac{1}{1 + N_{it} \frac{O(1 + \beta N_g + \gamma \vartheta N_g + 2MQ(N_{int} + N_R))}{O(1 + \beta N_g + \gamma \vartheta N_g)}} = \frac{1}{1 + N_{it} \left(1 + 2 \frac{O(MQ(N_{int} + N_R))}{O(1 + \beta N_g + \gamma \vartheta N_g)} \right)}. \end{aligned} \quad (5.54)$$

При цьому сумою $O(V_{init}) + O(\chi_{init}) + O(R_{init})$ в (5.52) зневажаємо, оскільки вона, принаймні, у N_{it}^2 разів менше, ніж вираз (5.53). У (5.53) також не будемо враховувати оцінку $O(G)$, оскільки вона є істотно меншою, ніж величина $N_{it}(O(RS^{(i,j)}) + O(RS_G^{(i)}))$

Вище відзначено, що кількість параметрів N_g моделі, що налаштовуються, є істотно меншою у порівнянні з загальною кількістю елементів множини $S = \langle P, T \rangle$ ($N_g \ll MQ$), оскільки синтезована модель повинна мати властивості узагальнення. Будемо вважати, що запропонований паралельний метод параметричного синтезу нейро-нечітких мереж використовується для настроювання $N_g \sim 10^2$ параметрів нейромоделі по вибірці, що містить $Q \sim 10^2$ спостережень, які описуються $M \sim 10^1$ ознаками, при цьому кількість правил – $N_R \sim 10^1$, кількість інтервалів розбиття значень ознак – $N_{int} \sim 10^1$, максимально припустима кількість ітерацій випадкового пошуку – $N_{it} \sim 10^1$. Підставляючи порядки відповідних величин у вираз (5.54), одержуємо порядок частки обчислень α_{serial} , що приходяться на послідовні етапи методу (5.55):

$$\alpha_{serial} \sim \frac{1}{1 + N_{it} \left(1 + 2 \frac{O(MQ(N_{int} + N_R))}{O(1 + \beta N_g + \gamma \vartheta N_g)} \right)} \approx 10^{-3}. \quad (5.55)$$

Важливо відзначити, що порядки величин N_{int} , N_R і N_{it} , як правило, вище тих, які були використані при оцінюванні α_{serial} , тому порядок величини α_{serial} на практиці може бути істотно меншим за наведений у (5.55).

Як видно з (5.55), частка послідовних операцій $\alpha_{serial} \approx 10^{-3}$ мізерно мала. Частку паралельних операцій α_{paral} оцінимо в такий спосіб (5.56):

$$\alpha_{paral} = 1 - \alpha_{serial} \approx 1 - 10^{-3} = 0,999. \quad (5.56)$$

Теоретичне прискорення $Speedup_{pr}$ процесу параметричного синтезу нейро-нечітких моделей, що може бути отримане при використанні запропонованого методу на N_{pr} процесорах паралельної системи, визначимо, використовуючи закон Амдала [136–139] (5.57):

$$Speedup_{pr} = \frac{1}{\alpha_{serial} + \frac{1 - \alpha_{serial}}{N_{pr}}} \approx \frac{1}{10^{-3} + \frac{1 - 10^{-3}}{N_{pr}}} = \frac{N_{pr}}{10^{-3} N_{pr} + 0,999}. \quad (5.57)$$

При $N_{pr} = 4$ значення теоретичного прискорення паралельної системи – $Speedup_4 = 3,988$, при $N_{pr} = 16$: $Speedup_{16} = 15,76$. Такі значення величини $Speedup_{pr}$ показують теоретичну здатність розробленого методу продемонструвати істотне прискорення при його використанні в паралельній системі.

Ефективність $Efficiency_{pr}$ паралельної системи при використанні запропонованого методу визначимо за формулою (5.58):

$$Efficiency_{pr} = \frac{Speedup_{pr}}{N_{pr}} = \frac{1}{N_{pr}} \frac{N_{pr}}{10^{-3} N_{pr} + 0,999} = \frac{1}{10^{-3} N_{pr} + 0,999}. \quad (5.58)$$

При $N_{pr} = 4$ значення ефективності паралельної системи – $Efficiency_4 = 0,997$, при $N_{pr} = 16$: $Efficiency_{16} = 0,985$. Як видно, значення

оцінки $Efficiency_{pr}$ при різних N_{pr} близько до одиниці, що свідчить про високу ефективність запропонованого паралельного методу параметричного синтезу нейро-нечітких моделей.

Відзначимо, що закон Амдала не враховує витрати, пов'язані з комунікацією між процесами (пересиланням необхідної інформації), тому реальне прискорення буде нижче оціненого. Для оцінювання відповідних характеристик доцільно виконати експериментальне дослідження запропонованого методу.

5.4 Висновки за розділом 5

Запропоновано модель подання стохастичного пошуку у ярусно-паралельній формі для параметричного синтезу нейро-нечітких мереж відрізняється використанням апріорної інформації про навчальну вибірку та просторове розташування рішень, що дозволяє більш детально досліджувати області можливих оптимумів та скоротити час настроювання параметрів синтезованих діагностичних нейромоделей.

Розроблено метод параметричної ідентифікації нейро-нечітких мереж на основі паралельного випадкового пошуку, що для настроювання параметрів синтезованих моделей (параметри функцій належності та вагові коефіцієнти нейроелементів) використовує ймовірнісну оптимізацію, початкову множину рішень формує з урахуванням інформації про навчальну вибірку (враховується значущість термів ознак, використовуючи щільність розташування екземплярів навчальної множини у відповідному термі та ступінь його впливу на значення вихідного параметра), що дозволяє наблизити початкові точки пошуку до областей розташування екстремумів і прискорити процес оптимізації.

З метою більш детального дослідження областей локальних оптимумів у запропонованому методі виконується розбиття поточної множини рішень на підмножини з наступним пошуком оптимумів у кожній з них на відповідних процесах паралельної системи. При цьому формування відповідних підмножин відбувається таким чином, щоб кожен набір являв собою групу компактно розташованих рішень у просторі елементів (параметрів моделі), які налаштовуються, що дозволяє враховувати інформацію про просторове розташування рішень і більш детально досліджувати області розташування екстремальних рішень за допомогою випадкового пошуку.

Розроблені оператори формування нової множини рішень враховують особливості розташування (діапазон значень) параметрів, що налаштовуються, їхній тип (параметри функцій належності нейронів, вагові коефіцієнти нейроелементів), пристосованість рішень-батьків, а також допускають вихід за межі відповідних діапазонів, що дозволяє розширювати область пошуку та виходити з можливих областей локальних екстремумів при синтезі діагностичних нейро-нечітких моделей.

Наведено теоретичні оцінки обчислювальної складності запропонованого методу синтезу нейро-нечітких моделей, що свідчать про високу ефективність застосування паралельного підходу і випадкового пошуку для побудови діагностичних нейромоделей на основі заданих наборів прецедентів.

Список використаних джерел у цьому розділі наведено у повному списку використаних джерел під номерами [1, 6, 9, 24, 45, 47, 48, 57–63, 136–139, 198, 204–211, 217–219, 241, 242, 249–256, 267–269, 299, 323–332].

6 МЕТОД ДОНАВЧАННЯ ДІАГНОСТИЧНИХ НЕЙРО-НЕЧІТКИХ МОДЕЛЕЙ

У процесі експлуатації інтелектуальних систем діагностування і неруйнівного контролю якості виникає нова інформація про діагностовані об'єкти [1–8, 17–22]. При цьому інформація, знову отримана за результатами вимірювань діагностованих об'єктів, може як істотно суперечити наявній діагностичній моделі, так і виходити за межі її компетенції у випадку, якщо при побудові моделі не використовувалися спостереження з тієї ж області простору ознак, що і нові спостереження. У таких випадках, як правило, виконують повторний синтез діагностичної моделі, використовуючи дані попередніх і нових вимірювань [1–8, 23, 24, 37]. Однак при роботі з даними великого обсягу час повторного синтезу моделей у нейро-нечіткому базисі може бути значним, що в багатьох практичних застосуваннях є неприйнятним. Тому в процесі експлуатації систем діагностування актуальною є задача адаптації раніше навчених моделей шляхом їхньої модифікації на основі нових спостережень. У цьому розділі розробляється метод донавчання діагностичних нейро-нечітких моделей.

6.1 Формалізація завдання донавчання діагностичних нейро-нечітких моделей

Нехай задано:

1) вибірку даних $S = \langle P, T \rangle$, що містить Q екземплярів, кожний з яких характеризується значеннями ознак $p_{q1}, p_{q2}, \dots, p_{qM}$ і вихідного параметра t_q , $q = 1, 2, \dots, Q$, $m = 1, 2, \dots, M$;

2) синтезовану за набором спостережень $S = \langle P, T \rangle$ нейро-нечітку модель $NFN = NFN(struct, param)$ з визначеною структурою $struct$ (набором обчислювальних елементів, зв'язаних певним чином) і набором параметрів $param = param(struct)$;

3) набір даних $S' = \langle P', T' \rangle$, отриманий у результаті нових Q' вимірювань досліджуваного (діагностованого) об'єкта.

Тоді задача донавчання моделі $NFN(struct, param)$ полягає в тому, щоб одержати нову модель $NFNN = NFNN(structN, paramN)$ шляхом модифікації існуючої моделі $NFN(struct, param)$ з урахуванням нових даних $S' = \langle P', T' \rangle$ таким чином, щоб забезпечувалося прийнятне значення заданого критерію якості G нейромоделі $NFNN : G(NFNN, S \cup S') \rightarrow \min$. Як цільовий критерій G при навчанні нейро-нечітких моделей можуть бути використані, наприклад, мінімум помилки розпізнавання (у задачах з дискретним виходом T) або мінімум середньоквадратичної помилки (у випадку, коли вихідний параметр T може приймати дійсні значення з деякого діапазону $T \in [t_{\min}; t_{\max}]$).

Для донавчання нейро-нечітких моделей пропонується корегувати наявну модель $NFN(struct, param)$ шляхом упровадження додаткових структурних обчислювальних елементів, які враховують особливості нового набору даних $S' = \langle P', T' \rangle$. При визначенні налаштовуваних параметрів додаткових структурних обчислювальних елементів (коригувальних блоків моделі) у розробленому методі пропонується використовувати інформацію про значення координат коригувальних екземплярів (нових спостережень), а також інформацію про ступінь їх належності до кластерів у просторі ознак. Це дозволить при визначенні налаштовуваних параметрів підвищити внесок тих екземплярів, які характеризуються високими оцінками ступеню належності до конкретного кластеру.

6.2 Витяг коригувальних екземплярів

У запропонованому методі [333] спочатку виконується етап витягу коригувальних екземплярів з вибірки $S' = \langle P', T' \rangle$. Коригувальними екземплярами cs'_q будемо вважати ті спостереження з вибірки $S' = \langle P', T' \rangle$, діагностування за якими на основі наявної (базової) моделі $NFN(struct, param)$ приводить до некоректних результатів. Отже, використовувана діагностична модель NFN має потребу в коригуванні саме за допомогою екземплярів cs'_q .

Тому для побудови множини коригувальних екземплярів CS' всі екземпляри s'_q вибірки $S' = \langle P', T' \rangle$ пропускаються через модель NFN , у результаті чого обчислюється значення вихідного параметра $t'_q(NFN)$ кожного q -го екземпляра вибірки $S' = \langle P', T' \rangle$ [333, 334]. Потім виконується порівняння реального t'_q і модельного $t'_q(NFN)$ значень вихідного параметра:

$$|t'_q - t'_q(NFN)| \geq \varepsilon_{\min}, \quad (6.1)$$

де t'_q – вимірне значення вихідного параметра q -го екземпляра s'_q вибірки $S' = \langle P', T' \rangle$;

$t'_q(NFN)$ – значення вихідного параметра q -го екземпляра s'_q вибірки $S' = \langle P', T' \rangle$, обчислене шляхом підстановки вимірних значень вхідних ознак p'_{qm} q -го екземпляра у модель NFN ;

ε_{\min} – мінімально прийнятна розбіжність реального і модельного значень вихідного параметра.

Умова (6.1) застосовується при розв'язанні задач оцінювання (при дійсних значеннях вихідного параметра T). При розв'язанні задач

розпізнавання (при дискретних значеннях вихідного параметра T) використовується така умова: $t'_q \neq t'_q(NFN)$.

При виконанні наведених вище умов q -й екземпляр s'_q вибірки $S' = \langle P', T' \rangle$ вважається коригувальним і заноситься у множину CS' : $CS' = CS' \cup s'_q$. Таким чином, у результаті виконання етапу витягу коригувальних екземплярів виключаються з подальшого розгляду ті екземпляри вибірки $S' = \langle P', T' \rangle$, які є подібними до екземплярів вхідної вибірки $S = \langle P, T \rangle$, і, отже, не впливають на якість розпізнавання або оцінювання за моделлю NFN .

Надалі екземпляри cs'_q множини CS' можуть використовуватися в якості сингтонів при побудові нового блоку $NB(structNB, paramNB)$, що вводиться разом із уже наявною моделлю $NFN(struct, param)$ в нову модель $NFNN = NFNN(structN, paramN)$.

Однак при обробці великих даних кількість екземплярів множини CS' може виявитися істотною, що приведе до значного збільшення структурної і параметричної складності нової моделі $NFNN$. Крім того, багато екземплярів множини CS' можуть бути близькими один до одного в просторі ознак і, по суті, бути схожими. Отже, включення всіх екземплярів $cs'_q \in CS'$ в якості правил нового блоку NB моделі $NFNN$ може також привести до втрати її узагальнювальних здібностей.

6.3 Групування коригувальних екземплярів

Враховуючи вище зазначене, доцільно до побудови блоку NB виконати етап групування коригувальних екземплярів множини CS' з виділенням

найбільш значущих з них $csInf'_q$, що концентрують біля себе деяку множину подібних близько розташованих екземплярів.

Для цього пропонується виконувати кластерний аналіз екземплярів множини CS' в просторі ознак P . Кількість кластерів N_{Cl} у розробленому методі визначається пропорційно кількості правил N_R у наявній моделі NFN , а також частки екземплярів $|CS'|$ множини CS' по відношенню до кількості екземплярів Q у множині $S = \langle P, T \rangle$ (6.2):

$$N_{Cl} = \text{Round}\left(\frac{|CS'|}{Q} N_R\right), \quad (6.2)$$

де $\text{Round}(a)$ – функція, що повертає результат округлення числа a до найближчого більшого цілого числа;

$|CS'|$ – кількість екземплярів cs'_q множини CS' ;

N_R – кількість правил моделі NFN .

Після визначення кількості кластерів N_{Cl} виконується початкове розбиття екземплярів $cs'_q \in CS'$ по кластерах. Для цього визначається множина $C = \{C_1, C_2, \dots, C_{N_{Cl}}\}$ центрів кластерів, де $C_j = \{C_{1j}, C_{2j}, \dots, C_{Mj}\}$ – центр j -го кластера, $j = 1, 2, \dots, N_{Cl}$. Центри C_j можуть вибиратися випадковим чином серед екземплярів cs'_q множини CS' . Також можливе створення множини $C = \{C_1, C_2, \dots, C_{N_{Cl}}\}$ з урахуванням просторового розташування екземплярів $cs'_q \in CS'$. Для цього спочатку випадковим чином з CS' вибирається екземпляр cs'_a , що вважається центром першого кластера $C_1 = \{cs'_{1a}, cs'_{2a}, \dots, cs'_{Ma}\}$. Потім як центр другого кластера C_2 вибирається екземпляр cs'_b , найбільш віддалений від екземпляра cs'_a . Центр третього кластера C_3 вибирається таким чином, щоб він був максимально віддалений від центрів першого і другого кластерів. Така

процедура продовжується доти, поки не буде сформовано N_{Cl} . При великому значенні N_{Cl} такий підхід буде пов'язаний з необхідністю проведення складних обчислень, обумовлених пошуком екземплярів, які характеризуються найбільшою відстанню до поточної множини уже визначених центрів кластерів. Тому даний підхід доцільно застосовувати при невеликих значеннях кількості кластерів N_{Cl} або комбінувати його з підходом, що передбачає випадкове формування множини $C = \{C_1, C_2, \dots, C_{N_{Cl}}\}$ центрів кластерів.

Потім виконується генерація елементів u_{qj} , що визначають належність q -го екземпляра cs'_q до j -го кластера C_j . На відміну від методу нечітких середніх [198], використовуваного як базис, у розробленому методі при створенні початкового розбиття екземплярів генерацію елементів u_{qj} , будемо виконувати не випадковим чином, а з урахуванням розташування екземплярів $cs'_q \in CS'$ у просторі ознак P . Для цього визначаються відстані $D(cs'_q, C_j)$ від екземпляра cs'_q до центра C_j кожного кластера, $j = 1, 2, \dots, N_{Cl}$. Як метрику для визначення відстані $D(cs'_q, C_j)$ можна використовувати Евклідову метрику (6.3):

$$D(cs'_q, C_j) = \sqrt{\sum_{m=1}^M (cs'_{mq} - C_{mj})^2}, \quad (6.3)$$

де cs'_{mq} і C_{mj} – m -ті координати q -го екземпляра $cs'_q \in CS'$ і центра j -го кластера C_j , відповідно.

Належність u_{qj} q -го екземпляра cs'_q до j -го кластера C_j обчислюється за формулою (6.4):

$$u_{qj} = \left(\sum_{JA=1}^{N_{cl}} \left(\frac{D(cs'_q, C_j)}{D(cs'_q, C_{JA})} \right)^{\frac{2}{mp-1}} \right)^{-1}, \quad (6.4)$$

де mp – параметр методу, що обирається користувачем, як правило, $mp = 2$.

У випадку, коли екземпляр cs'_q є центром j -го кластера C_j ($D(cs'_q, C_j) = 0$), тоді встановлюється: $u_{qj} = 1$, $u_{qJA} = 0, \forall JA \neq j$.

Далі за формулою (6.5) обчислюється значення функції $J(R^{(i)}, u^{(i)}, C^{(i)})$, що визначає якість нечіткого розбиття $R^{(i)}$ на i -й ітерації кластерного аналізу:

$$J(R^{(i)}, u^{(i)}, C^{(i)}) = \sum_{q=1}^{|CS'|} \sum_{j=1}^{N_{cl}} (u_{qj})^{mp} D^2(cs'_q, C_j). \quad (6.5)$$

Після цього виконується перевірка критеріїв (6.6) і (6.7) закінчення процедури кластерного аналізу:

$$\left| J_{old}(R^{(i)}, u^{(i)}, C^{(i)}) - J(R^{(i)}, u^{(i)}, C^{(i)}) \right| \leq \varepsilon_J, \quad (6.6)$$

$$i \geq \text{maxIterCIA}, \quad (6.7)$$

де $J_{old}(R^{(i)}, u^{(i)}, C^{(i)})$ і $J(R^{(i)}, u^{(i)}, C^{(i)})$ – значення критерію якості розбиття J на попередній і поточній ітераціях, відповідно;

ε_J – мінімально прийнятна зміна значення критерію J .

При цьому нерівність (6.6) відображає умову, виконання якої характеризує занадто мала зміна значення цільової функції $J(R^{(i)}, u^{(i)}, C^{(i)})$, і відповідно, недоцільність подальшого пошуку оптимального розбиття $R^{(i)}$. Умова (6.7) відображає ситуацію, коли поточна кількість ітерацій i досягає максимально припустимого значення maxIterCIA . При невиконанні обох умов

(6.6) і (6.7) виконується визначення нових значень координат центрів кластерів, використовуючи формулу (6.8):

$$C_{mj} = \frac{\sum_{q=1}^{|CS'|} (u_{qj})^{mp} cs'_{mq}}{\sum_{q=1}^{|CS'|} (u_{qj})^{mp}}. \quad (6.8)$$

Потім, використовуючи формули (6.3) – (6.5) виконується пошук нового нечіткого розбиття $R^{(i+1)}$ (перерахунок належностей u_{qj}). Така процедура повторюється доти, поки не буде виконано хоча б одну з умов (6.6) чи (6.7).

Таким чином, у результаті виконання етапу групування коригувальних екземплярів формуються множина центрів кластерів $C = \{C_1, C_2, \dots, C_{N_{CI}}\}$ і множина належностей u_{qj} екземплярів cs'_q до відповідних кластерів.

6.4 Побудова коригувального блоку

Після групування коригувальних екземплярів виконується етап побудови коригувального блоку NB .

У випадку, коли модель $NFN(struct, param)$, що модифікується, використовує в якості базису нейро-нечітку мережу ANFIS [217, 249–256], тоді структура коригувального блоку NB буде також базуватися на мережі ANFIS. Графічну інтерпретацію коригувального блоку NB наведено на рис. 6.1.

При цьому кількість N_{RNB} вузлів другого шару, що відповідають нечітким правилам, у коригувальному блоці NB пропонується прийняти такою, що дорівнює кількості кластерів (правил), виділених на попередньому етапі:

$$N_{RNB} = N_{CI}.$$

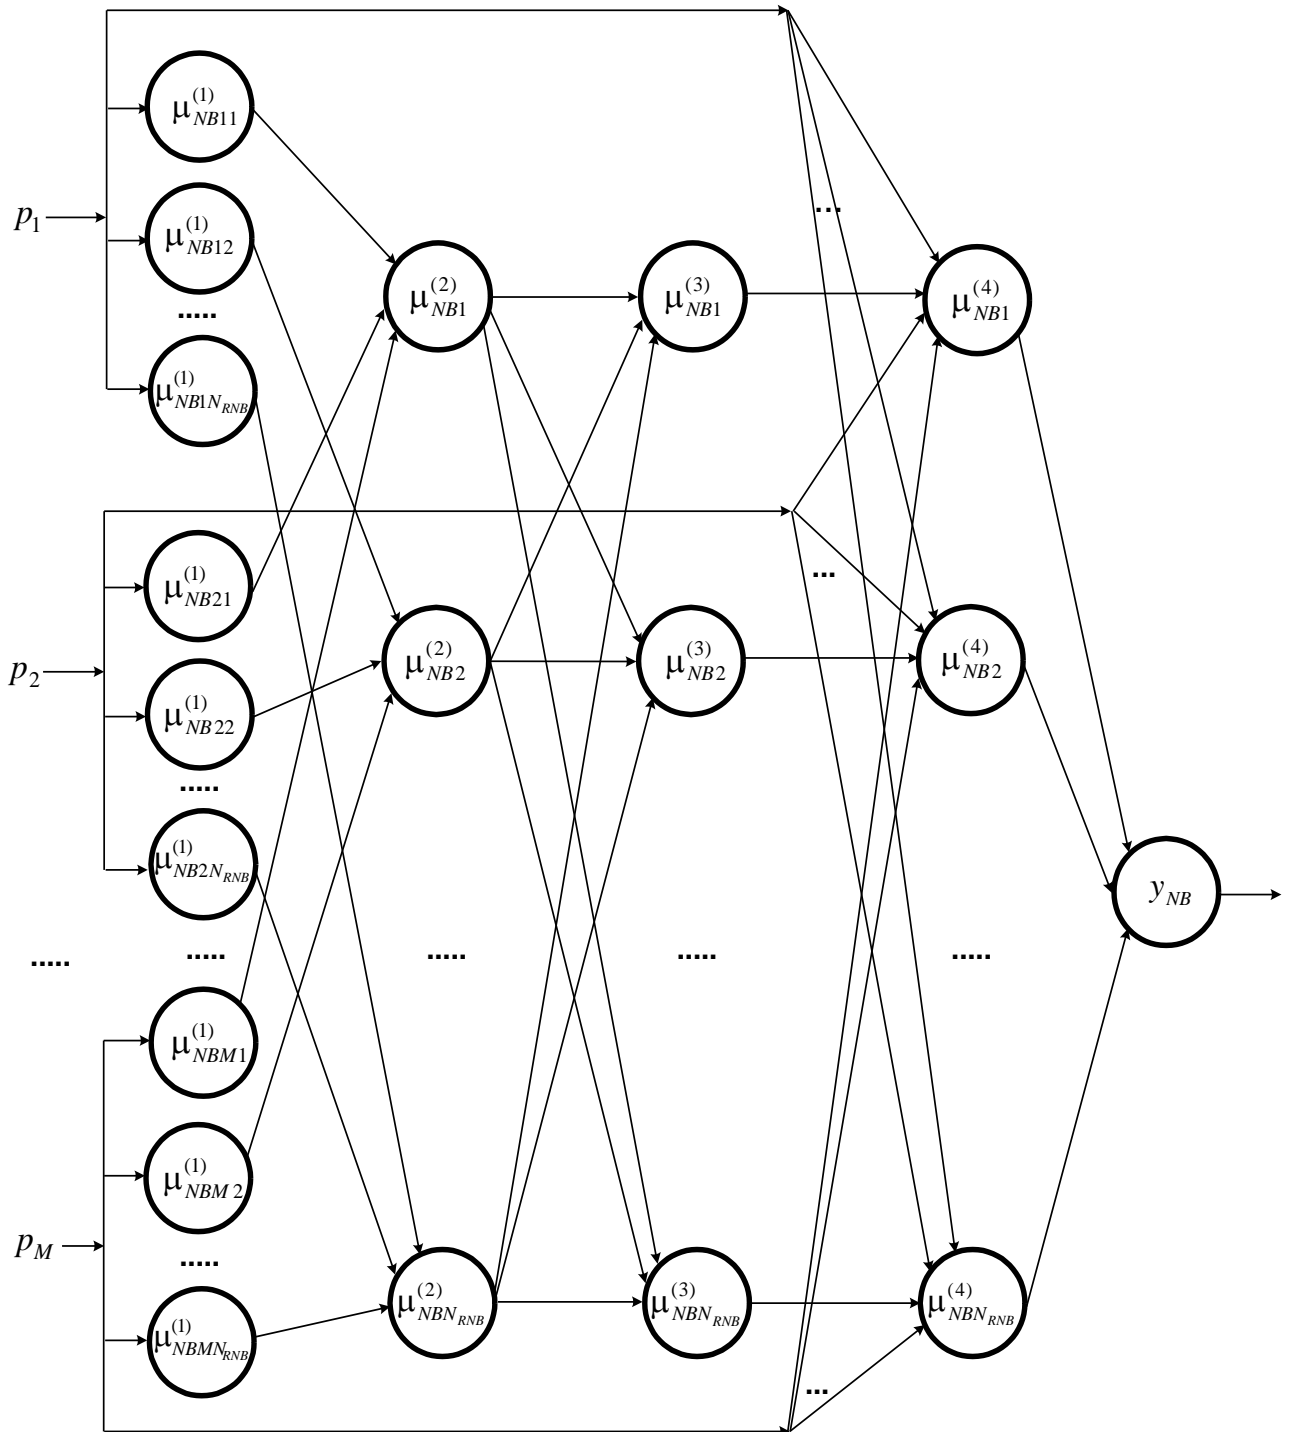


Рисунок 6.1 – Графічна інтерпретація коригувального блоку NB при модифікації моделей NFN , що використовують як базис нейро-нечітку мережу ANFIS [217, 249–256]

Враховуючи особливості обчислення параметра N_{Cl} в пропонуваному методі, кількість правил N_{RNB} блоку NB буде пропорційною до кількості правил N_R у наявній моделі NFN , а також до частки екземплярів $|CS'|$ множини CS' по відношенню до кількості екземплярів Q у множині $S = \langle P, T \rangle$. Таким чином, структурна складність коригувального блоку N_{RNB} буде пропорційною аналогічній величині вихідної моделі NFN і долі нових екземплярів множини CS' .

Нейроелементи першого шару, що визначають ступінь належності значення вхідного параметра p_m відповідному нечіткому терму ft_{mj} ($j = 1, 2, \dots, N_{RNB}$), з'єднані з відповідними вузлами другого шару. Таким чином, у сукупності вузли першого і другого шарів утворюють антецеденти нечітких правил NR_j .

Інформацію, отриману на попередніх етапах розробленого методу донавчання нейро-нечітких моделей (множину коригувальних екземплярів CS' , множину центрів кластерів $C = \{C_1, C_2, \dots, C_{NCl}\}$ і множину належностей u_{qj} екземплярів cs'_q відповідним кластерам), будемо використовувати для визначення налаштовуваних параметрів функцій належності $\mu_{NBmj}^{(1)}$ ($m = 1, 2, \dots, M$, $j = 1, 2, \dots, N_{RNB}$). Як функції $\mu_{NBmj}^{(1)}$, що визначають ступінь належності значення m -го вхідного параметра p_m j -му нечіткому терму ft_{mj} в коригувальному блоці NB будемо використовувати функції належності [217, 249–256] вигляду (6.9):

$$\mu_{NBmj}^{(1)}(p_m) = \exp\left(-\frac{(p_m - b_{mj})^2}{2d_{mj}^2}\right), \quad (6.9)$$

де b_{mj} і d_{mj} – налаштовувані параметри функції належності.

Як параметр b_{mj} ($m = 1, 2, \dots, M$, $j = 1, 2, \dots, N_{RNB}$), що визначає зсув центра функції щодо центра координат осі ознаки p_m , будемо використовувати m -у координату j -го центра кластера C_j з множини $C = \{C_1, C_2, \dots, C_{NCl}\}$, сформованої на попередньому етапі.

Як параметр d_{mj} будемо використовувати середньоквадратичне відхилення коригувальних екземплярів $cs'_q \in CS'$ відносно j -го центра кластера C_j по осі m -ї ознаки. При цьому також враховується належність u_{qj} q -го коригувального екземпляра $cs'_q \in CS'$ j -му кластеру C_j :

$$d_{mj} = \sqrt{\frac{1}{|CS'|} \sum_{q=1}^{CS'} u_{qj} (cs'_{mq} - C_{mj})^2}. \quad (6.10)$$

Використання запропонованих виразів для визначення налаштовуваних параметрів b_{mj} та d_{mj} функцій належності $\mu_{NBmj}^{(1)}$ дозволяє у процесі оцінювання нових екземплярів $s_{new} \notin S$ за допомогою коригувального блоку NB активувати ті нечіткі терми ft_{mj} ($m = 1, 2, \dots, M$), що у сукупності відповідають визначеним кластерам C_j (нечітким правилам NR_j).

Визначивши $\mu_{NBmj}^{(1)}$ з урахуванням обчислених оцінок b_{mj} , d_{mj} , можна обчислити значення виходів другого шару мережі $\mu_{NBj}^{(2)}$, що визначають ступінь виконання j -го правила NR_j , за формулою:

$$\mu_{NBj}^{(2)}(s_{new}) = \bigcap_{m=1}^M \mu_{NBmj}^{(1)}(p_m(s_{new})), \quad (6.11)$$

де $p_m(s_{new})$ – m -та координата оцінюваного екземпляра $s_{new} \notin S$.

Вузли третього шару визначають відносний ступінь виконання j -го правила NR_j :

$$\mu_{NBj}^{(3)}(s_{new}) = \frac{\mu_{NBj}^{(2)}(s_{new})}{\sum_{JB=1}^{N_{RNB}} \mu_{NBj}^{(2)}(s_{new})}. \quad (6.12)$$

Нейроелементи четвертого шару $\mu_{NBj}^{(4)}$ ($j=1,2,\dots,N_{RNB}$) відповідають функціям y_{NBj} , що визначають значення виходу мережі у випадку спрацьовування відповідного правила NR_j . У такий спосіб кожний j -й вузол мережі визначає внесок нечіткого правила NR_j в загальний вихід мережі y_{NB} . Функції y_{NBj} , як правило, представляються у вигляді лінійної регресії, отже, значення виходів вузлів четвертого шару $\mu_{NBj}^{(4)}$ можуть бути обчислені за формулою (6.13):

$$\mu_{NBj}^{(4)}(s_{new}) = \mu_{NBj}^{(3)}(s_{new})y_{NBj}(s_{new}) = \mu_{NBj}^{(3)}(s_{new}) \left(\sum_{m=0}^M w_{mj} (p_m(s_{new})) \right), \quad (6.13)$$

де w_{mj} – налаштовувані параметри функції y_{NBj} .

При цьому вважається, що $p_0(s_{new})=1$, а коефіцієнт w_{0j} відповідає значенню вільного члена лінійної регресії (6.13). Спрощено функцію y_{NBj} можна представити в такий спосіб: $y_{NBj} = \sum_{m=0}^M w_{mj} p_m$. Як базис функцій y_{NBj} можуть використовуватися і більш складні нелінійні залежності.

Таким чином, для синтезу коригувального блоку NB необхідно відновити функції y_{NBj} , визначивши для цього значення параметрів w_{mj} , що налаштовуються.

Для визначення значень параметрів w_{mj} у розробленому методі пропонується використовувати інформацію не тільки про значення координат коригувальних екземплярів $cs'_q \in CS'$, але також інформацію про ступінь їхньої належності u_{qj} до кожного з кластерів Cl_j (по суті, до нечіткого правила NR_j), які визначаються центрами $C = \{C_1, C_2, \dots, C_{NCl}\}$. Це дозволить врахувати значущість екземплярів $cs'_q \in CS'$ для відновлення функцій y_{NBj} , що відповідають кластерам Cl_j , і при визначенні параметрів w_{mj} функції y_{NBj} підвищити внесок тих екземплярів, які характеризуються високими оцінками ступеню належності u_{qj} кластеру Cl_j .

Пропонується два підходи для визначення значень параметрів w_{mj} .

Перший підхід передбачає побудову моделей y_{NBj} на основі коригувальних екземплярів cs'_q з максимальними оцінками u_{qj} належності відповідним кластерам Cl_j . При цьому для кожного кластера Cl_j (правила NR_j) вибираються екземпляри cs'_q з найбільшими значеннями величини u_{qj} . Тобто вважається, що екземпляр cs'_q відноситься до кластера Cl_j ($cs'_q \in Cl_j$) при виконанні умови $u_{qj} = \max_q(u_{qj})$. Якщо ця умова виконується, то екземпляр cs'_q додається у множину Set_j екземплярів, що відносяться до кластера Cl_j : $Set_j = Set_j \cup cs'_q$. Далі, використовуючи екземпляри множини Set_j , виконується відновлення функції y_{NBj} , застосовуючи для цього відомі методи параметричного синтезу моделей [44–63].

Другий підхід передбачає використання всіх екземплярів cs'_q множини CS' для побудови всіх моделей y_{NBj} . При відновленні функції y_{NBj} , що визначає вихід j -го вузла четвертого шару коригувального блоку NB , використовуються всі екземпляри $cs'_q \in CS'$, а також враховується належність u_{qj} кожного з них j -му кластеру Cl_j (правилу NR_j).

У процесі відновлення функції y_{NBj} як цільову функцію E будемо використовувати функцію (6.14), що являє собою модифіковану функцію середньоквадратичної помилки [57–63]:

$$E_j = \frac{1}{|CS'|} \sum_{q=1}^{|CS'|} u_{qj} (t_q - t_{q\text{mod}})^2, \quad (6.14)$$

де $t_{q\text{mod}}$ – модельне значення вихідного параметра q -го екземпляра cs'_q , розраховане за синтезованою моделлю y_{NBj} :

$$t_{q\text{mod}} = y_{NBj}(cs'_q) = \sum_{m=0}^M w_{mj} (p_m(cs'_q)). \quad (6.15)$$

Така функція крім відхилення між реальним t_q і модельним значенням $t_{q\text{mod}}$ вихідного параметра екземплярів cs'_q використовує також інформацію про ступінь належності u_{qj} цього екземпляра j -му кластеру Cl_j як оцінку значущості екземпляра cs'_q для відновлення функції y_{NBj} .

Підставляючи (6.15) у (6.14), скорочуючи отриманий вираз на множник $\frac{1}{|CS'|}$ і врахувавши, що $p_m(cs'_q) = p_{qm}$, одержуємо цільову функцію виду (6.16):

$$E_j = \sum_{q=1}^{|CS'|} u_{qj} \left(t_q - \sum_{m=0}^M w_{mj} p_{qm} \right)^2 = \sum_{q=1}^{|CS'|} \left(u_{qj} (t_q)^2 - 2u_{qj} t_q \sum_{m=0}^M w_{mj} p_{qm} + u_{qj} \left(\sum_{m=0}^M w_{mj} p_{qm} \right)^2 \right). \quad (6.16)$$

Для визначення значень налаштовуваних параметрів w_{mj} знайдемо такі їхні значення, при яких досягається оптимум цільового критерію: $E_j \rightarrow opt$. Для цього визначимо часткові похідні по параметрах w_{mj} цільового критерію

E_j , як функції багатьох перемінних: $E_j = E_j(w_{0j}, w_{1j}, w_{Mj})$, після чого вирішимо систему рівнянь (6.17):

$$\frac{\partial E_j}{\partial w_{mj}} = 0, \quad m = 0, 1, 2, \dots, M. \quad (6.17)$$

Вираз (6.17) являє собою систему, що складається з $(M + 1)$ лінійних рівнянь вигляду (6.18)

$$\frac{\partial E_j}{\partial w_{mj}} = \sum_{q=1}^{|\text{CS}'|} \left(-2u_{qj} t_q P_{qm} + 2u_{qj} P_{qm} \left(\sum_{m=0}^M w_{mj} P_{qm} \right) \right) = 0, \quad m = 0, 1, 2, \dots, M, \quad (6.18)$$

або

$$\sum_{q=1}^{|\text{CS}'|} (u_{qj} P_{qm} (w_{0j} P_{q0} + w_{1j} P_{q1} + \dots + w_{Mj} P_{qM})) = \sum_{q=1}^{|\text{CS}'|} (u_{qj} t_q P_{qm}), \quad m = 0, 1, 2, \dots, M.$$

Виконуючи подальші перетворення, одержуємо, що m -е рівняння системи (6.17) може бути записане у вигляді (6.19):

$$w_{0j} \sum_{q=1}^{|\text{CS}'|} (u_{qj} P_{qm} P_{q0}) + w_{1j} \sum_{q=1}^{|\text{CS}'|} (u_{qj} P_{qm} P_{q1}) + \dots + w_{Mj} \sum_{q=1}^{|\text{CS}'|} (u_{qj} P_{qm} P_{qM}) = \sum_{q=1}^{|\text{CS}'|} (u_{qj} t_q P_{qm}). \quad (6.19)$$

Підставляючи значення $m = 0, 1, 2, \dots, M$ в (6.19) одержуємо систему лінійних алгебраїчних рівнянь (6.20):

$$\left\{ \begin{array}{l} w_{0j} \sum_{q=1}^{|CS'|} (u_{qj} P_{q0} P_{q0}) + w_{1j} \sum_{q=1}^{|CS'|} (u_{qj} P_{q0} P_{q1}) + \dots + w_{Mj} \sum_{q=1}^{|CS'|} (u_{qj} P_{q0} P_{qM}) = \sum_{q=1}^{|CS'|} (u_{qj} t_q P_{q0}); \\ w_{0j} \sum_{q=1}^{|CS'|} (u_{qj} P_{q1} P_{q0}) + w_{1j} \sum_{q=1}^{|CS'|} (u_{qj} P_{q1} P_{q1}) + \dots + w_{Mj} \sum_{q=1}^{|CS'|} (u_{qj} P_{q1} P_{qM}) = \sum_{q=1}^{|CS'|} (u_{qj} t_q P_{q1}); \\ \dots \\ w_{0j} \sum_{q=1}^{|CS'|} (u_{qj} P_{qM} P_{q0}) + w_{1j} \sum_{q=1}^{|CS'|} (u_{qj} P_{qM} P_{q1}) + \dots + w_{Mj} \sum_{q=1}^{|CS'|} (u_{qj} P_{qM} P_{qM}) = \sum_{q=1}^{|CS'|} (u_{qj} t_q P_{qM}). \end{array} \right. \quad (6.20)$$

Далі, розв'язуючи систему (6.20) відомими методами лінійної алгебри знаходяться шукані значення w_{mj} .

Як відзначено вище, в якості функції y_{NBj} можуть використовуватися не тільки лінійні функції вигляду $y_{NBj} = \sum_{m=0}^M w_{mj} p_m$, а і більш складні нелінійні залежності. У таких випадках пошук налаштовуваних параметрів w_{mj} функції y_{NBj} здійснюється шляхом оптимізації цільового функціонала (6.14) за допомогою відомих градієнтних (у випадку, якщо функції y_{NBj} диференційовані) або стохастичних (в інших випадках) методів.

Після визначення значень налаштовуваних параметрів w_{mj} функцій y_{NBj} можуть бути обчислені за формулою (6.13) значення виходів $\mu_{NBj}^{(4)}$ нейроелементів четвертого шару коригувального блоку NB . Потім обчислюється загальний вихід блоку NB (6.21):

$$y_{NB}(s_{new}) = \sum_{j=1}^{N_{RNB}} \mu_{NBj}^{(4)}(s_{new}). \quad (6.21)$$

6.5 Об'єднання наявної моделі та коригувального блоку

Потім виконується етап об'єднання наявної моделі NFN і коригувального блоку NB . На даному етапі відбувається узагальнення інформації про набори даних $S = \langle P, T \rangle$ і $S' = \langle P', T' \rangle$, що апроксимуються за допомогою моделі NFN і коригувального блоку NB , відповідно. Модифіковану модель $NFNN$ шляхом доповнення існуючої моделі $NFN(struct, param)$ коригувальним блоком NB наведено на рис. 6.2.

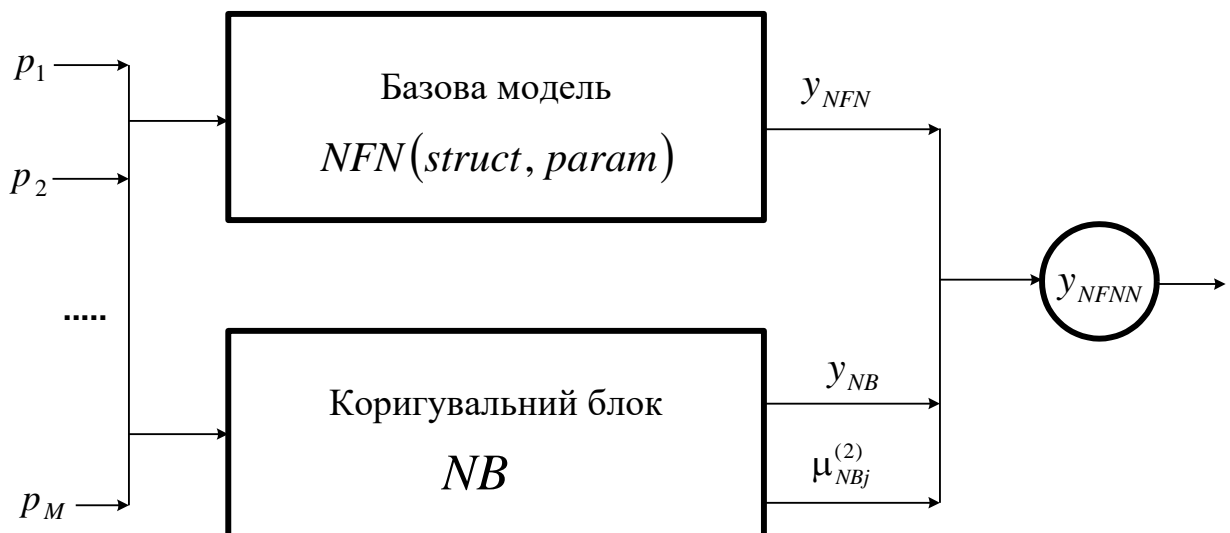


Рисунок 6.2 – Графічна інтерпретація модифікованої моделі $NFNN$

Для оцінювання значення вихідного параметра $t(s_{new})$ нового екземпляра $s_{new} \notin S$ за допомогою моделі $NFNN$, модифікованої (адаптованої до нових умов) на основі нових даних $S' = \langle P', T' \rangle$, пропонується використовувати формулу (6.22):

$$t(s_{new}) = y_{NFNN}(s_{new}) = \begin{cases} y_{NB}(s_{new}), & \bigcup_{j=1}^{N_{RNB}} \mu_{NBj}^{(2)} > \mu_{\min}; \\ y_{NFN}(s_{new}), & \bigcup_{j=1}^{N_{RNB}} \mu_{NBj}^{(2)} \leq \mu_{\min}, \end{cases} \quad (6.22)$$

де μ_{\min} – параметр, що визначає мінімально прийнятний ступінь належності екземпляра s_{new} множині даних $S' = \langle P', T' \rangle$, на основі якої був синтезований коригувальний блок NB .

Як видно, якщо новий екземпляр $s_{new} \notin S$ характеризується досить великим ступенем належності ($\bigcup_{j=1}^{N_{RNB}} \mu_{NBj}^{(2)} > \mu_{\min}$) до правил NR_j коригувального блоку NB (а відповідно, і до кластерів Cl_j , синтезованих на основі нового набору даних $S' = \langle P', T' \rangle$), то підсумкове значення y_{NFNN} обчислюється за допомогою коригувального блоку NB . У протилежному випадку вважається, що екземпляр s_{new} більше відноситься до вхідної множини $S = \langle P, T \rangle$, і значення y_{NFNN} приймається рівним вихідному значенню y_{NFN} базової моделі NFN .

Важливо відзначити, що запропонований підхід до побудови коригувальних блоків NB дозволяє синтезувати і впроваджувати в існуючі моделі нові блоки з появою нової інформації $S' = \langle P', T' \rangle$, діагностування по якій приводить до некоректних результатів роботи моделі $NFNN$. Таким чином, модель $NFNN$, наведена на рис. 6.2, може послідовно розширюватися шляхом додавання нових блоків NB , що узагальнюють інформацію про нові спостереження досліджуваних об'єктів.

Таким чином, запропонований метод донавчання діагностичних нейронечітких моделей дозволяє адаптувати до зміни середовища функціонування існуючі моделі шляхом їхньої модифікації з урахуванням інформації, отриманої в результаті нових спостережень. Запропонований метод передбачає виконання етапів витягу й групування коригувальних екземплярів, діагностування по яких

за допомогою існуючої моделі приводить до некоректних результатів, а також побудову коригувального блоку, що узагальнює дані коригувальних екземплярів, і впровадження його у вже існуючу модель. При визначенні налаштовуваних параметрів коригувального блоку в розробленому методі пропонується використовувати інформацію про значення координат коригувальних екземплярів, а також інформацію про ступінь їхньої належності до кластерів у просторі ознак (і, відповідно, до нечітких правил, представлених у коригувальному блоці). Це дозволяє врахувати значущість коригувальних екземплярів для відновлення функцій четвертого шару коригувального блоку і при визначенні параметрів, що налаштовуються, підвищити внесок тих екземплярів, які характеризуються високими оцінками ступеню належності конкретному кластеру.

Використання запропонованого методу донавчання діагностичних нейро-нечітких моделей дозволяє не виконувати ресурсномісткий процес повторної побудови діагностичної моделі на основі повного набору даних, використовувати вже наявну модель як обчислювальний блок нової моделі. Крім того, моделі, синтезовані за допомогою запропонованого методу характеризуються високою інтерпретовністю, оскільки кожен блок узагальнює інформацію про свій набір даних і як базис використовує нейро-нечіткі моделі.

6.6 Висновки за розділом 6

Розроблено метод донавчання діагностичних нейро-нечітких моделей, який дозволяє адаптувати до зміни середовища функціонування існуючі моделі шляхом їх модифікації з урахуванням інформації, отриманої в результаті нових спостережень. Запропонований метод передбачає виконання етапів видобування та групування коригувальних екземплярів, діагностування за

якими за допомогою існуючої моделі призводить до некоректних результатів, а також побудову коригувального блоку, який узагальнює дані коригувальних екземплярів, і впровадження його у вже існуючу модель. При визначенні параметрів, що настроюються, коригувального блоку в розробленому методі пропонується використовувати інформацію про значення координат коригувальних екземплярів, а також інформацію про ступінь їх належності до кластерів в просторі ознак (і, відповідно, нечітких правил, представлених у коригувальному блоці). Це дозволяє врахувати значущість коригувальних екземплярів для відновлення функцій четвертого шару коригувального блоку і при визначенні параметрів, що настроюються, підвищити вклад тих екземплярів, які характеризуються високими оцінками ступеню належності конкретному кластеру. Використання запропонованого методу донавчання діагностичних нейро-нечітких моделей дозволяє не виконувати ресурсномісткий процес повторної побудови діагностичної моделі на основі повного набору даних, використовувати вже наявну модель в якості обчислювального блоку нової моделі. Крім того, моделі, синтезовані за допомогою запропонованого методу, характеризуються високою інтерпретовністю, оскільки кожен блок узагальнює інформацію про свій набір даних і в якості базису використовує нейро-нечіткі моделі.

Список використаних джерел у цьому розділі наведено у повному списку використаних джерел під номерами [1–8, 17–24, 37, 44–63, 198, 217, 249–256, 333, 334].

7 ЕКСПЕРИМЕНТАЛЬНЕ ДОСЛІДЖЕННЯ МЕТОДІВ СИНТЕЗУ ДІАГНОСТИЧНИХ МОДЕЛЕЙ НА ОСНОВІ ОБЧИСЛЮВАЛЬНОГО ІНТЕЛЕКТУ

Як зазначено вище, розв'язання завдань технічного та медичного діагностування, а також неруйнівного контролю якості виробів пов'язано з необхідністю побудови діагностичних моделей [1, 6, 9, 24, 57–63], що дозволяють з високою точністю відносити діагностовані екземпляри до певних класів і є достатньо зрозумілими для експертів в прикладних областях.

У попередніх розділах запропоновано методи, які дозволяють розв'язувати задачі редукції даних навчальної вибірки, видобування правил, синтезу і донавчання діагностичних моделей на основі нейро-нечітких мереж. Метою цього розділу є експериментальне дослідження розроблених методів аналізу даних та побудови діагностичних моделей на основі нейро-нечітких мереж.

7.1 Умови та особливості проведення експериментальних досліджень методів синтезу діагностичних моделей на основі обчислювального інтелекту

Для перевірки ефективності розроблених методів аналізу даних та побудови діагностичних моделей на основі нейро-нечітких мереж розв'язувалися різні практичні завдання діагностування та розпізнавання, що характеризувалися різними властивостями навчальних вибірок даних $S = \langle P, T \rangle$ (кількість екземплярів Q , кількість атрибутів M , типи ознак та вихідного параметру, наявність пропущених значень та ін.).

Для проведення експериментального дослідження використовувалося таке устаткування: кластер Національного університету «Запорізька

політехніка» (процесори Intel E3200, оперативна пам'ять 1 ГБ DDR-2 на кожен вузол, комунікаційне середовище Gigabit Ethernet 1 Гб/с, middleware Torque і MPICH), кластер Інституту проблем моделювання в енергетиці імені Г.Є. Пухова НАН України, м. Київ (процесори Intel Xeon 5405, оперативна пам'ять – 4×2 ГБ DDR-2 на кожен вузол, комунікаційне середовище InfiniBand 20Гб/с, middleware Torque і OMPI), графічний процесор GPU NVIDIA GTX 285+ 240 ядер CUDA, графічний процесор GPU NVIDIA GTX 960 1024 ядра CUDA, персональний комп'ютер з процесором Intel Skylake та оперативною пам'яттю 4 ГБ DDR-4. При дослідженні паралельних методів використовувалися засоби бібліотеки MPI [151].

Запропоновані методи досліджувалися у порівнянні з існуючими методами, що дозволяють розв'язувати аналогічні завдання аналізу даних (відбору ознак, видобування правил та ін.) та синтезу діагностичних моделей. Фрагменти навчальних вибірок даних наведено у табл. А.1 – А.7. Враховуючи стохастичність багатьох розроблених та існуючих методів синтезу діагностичних моделей, як результати експериментів наведено усереднені значення критеріїв порівняння, отриманих внаслідок декількох запусків досліджуваних методів. Як критерії порівняння було використано критерії, що дозволяють оцінити ефективність методів для розв'язання відповідної задачі [335–348], зокрема використовувалися критерії оцінювання часу роботи методу, кількості ітерацій роботи методу до його зупинення, точності побудованої моделі, кількості відібраних ознак з заданої вибірки даних $S = \langle P, T \rangle$, кількість звертань до цільової функції, що необхідні для досягнення результату з заданою точністю, та ін.

7.2 Експериментальне дослідження методів видобування продукційних правил на основі інтелектуальних обчислень

З метою експериментального дослідження розробленого стохастичного методу синтезу дерев розв'язків виконаємо його порівняння його з відомими

аналогами (методом С4.5 [133–141], методом CART [133–141], а також еволюційним методом побудови дерев розв’язків [292]) шляхом розв’язання практичних задач прийняття рішень у технічному та медичному діагностуванні, зокрема завдання неруйнівного контролю якості кузовів автотранспортних засобів [277, 292]. Як важливі параметри при неруйнівному контролі якості кузовів автотранспортних засобів можна використовувати 18 точок, розташованих в області порога кузова та в областях кріплення петель для зборки кузова і начіпних вузлів [277, 292, 347]. При цьому в шести точках фіксуються відхилення по двох координатах (третя координата є базовою, унаслідок чого відхилення по даній координаті є нульовим), в інших дванадцятьох – виміряються всі три координати, отже, вибірка даних містила значення 48 вхідних параметрів. Також виділено 16 істотних вихідних параметрів, які характеризують деякі деформації, обумовлені відхиленнями номінальних розмірів чорного кузова, дверей і капота від еталонних розмірів (при цьому відхилення кожного з вимірюваних вхідних параметрів може знаходитися в межах допуску), а також іншими факторами, що виникають при зборці. Такі деформації приводять до утворення зазорів і сполучень між начіпними вузлами і кузовом (зазори і сполучення між дверима і порогом, капотом і крилом, передньою і задньою дверима та ін.), та є досить частими і помітними для покупців продукції. Усунення таких недоліків пов’язано з необхідністю розбирання кузова і начіпних вузлів, а також з повторним фарбуванням і зборкою, що ускладнює і здорожує процес виготовлення якісних виробів. Таким чином, необхідно синтезувати моделі залежностей показників, що характеризують істотні вихідні параметри, від 48 вхідних ознак. Фрагмент навчальної вибірки наведено у табл. А.1. Нижче наведено результати побудови однієї з моделей. Для інших параметрів отримано аналогічні результати.

Як критерій оцінювання інтерпретовності $Int(\chi_k)$ дерев розв’язків χ_k при використанні стохастичного й еволюційного методів використовувалося узагальнення рішень $Gener(\chi_k) = N_{leaf}(\chi_k) / Q$, оскільки кількість листів N_{leaf}

відповідає загальній кількості правил N_{RDT} , що видобуваються з дерева χ_k , і, отже, визначає структуру базу правил, синтезованої на основі дерева розв'язків χ_k . Коефіцієнти, що дозволяють врахувати важливість критеріїв $Int(\chi_k)$ та $E(\chi_k)$, вибиралися рівними 0,5 (кожен критерій $Int(\chi_k)$ та $E(\chi_k)$ в процесі експериментів мав однакову значущість), отже, цільова функція $G(\chi_k) = \gamma_1 Int(\chi_k) + \gamma_2 E(\chi_k)$ при стохастичному і еволюційному пошуку визначалася в такий спосіб: $G(\chi_k) = 0,5 Gener(\chi_k) + 0,5 E(\chi_k)$.

Результати експериментів по дослідженню різних методів синтезу дерев розв'язків при побудові діагностичної моделі якості кузовів автомобілів наведено в таблиці 7.1.

Таблиця 7.1 – Результати експериментів по дослідженню різних методів синтезу дерев розв'язків

Метод	N_{level}	N_{node}	N_{leaf}	$Gener$	$GenerM$	Br	G	$Idist$	t	E	E_t
CART[133–141]	8	95	48	0,279	0,023	0,37	0,166	0,012	15,12	0,052	0,093
C4.5 [133–141]	8	103	52	0,302	0,025	0,4	0,174	0,078	14,82	0,046	0,072
Еволюційний метод [292]	7	83	42	0,244	0,02	0,65	0,131	0,0041	7,42	0,018	0,031
Стохастичний метод [276]	7	73	37	0,215	0,018	0,57	0,116	0,0032	7,31	0,016	0,028

Як видно з таблиці, запропонований стохастичний метод та еволюційний метод синтезу дерев розв'язків дозволяють будувати більш прийнятні діагностичні моделі на основі дерев розв'язків (значення критерію G нижче в порівнянні з моделями, синтезованими на основі методів CART і C4.5 [133–141]). Це обґрунтовується тим, що такі методи не використовують жадібну стратегію. Розроблений стохастичний метод забезпечив побудову дерева розв'язків, що характеризується незначною кількістю структурних елементів ($N_{level} = 7$, $N_{node} = 73$, $N_{leaf} = 37$), а також високими

апроксимаційними (помилка навчальної вибірки склала $E = 0,016$) і узагальнювальними (помилка на тестових даних $E_t = 0,028$) здібностями, що досягається за рахунок використання в процесі синтезу інформації про інформативність ознак, складність синтезованого дерева та точність його розпізнавання.

Для оцінювання та порівняння узагальнювальних можливостей синтезованих діагностичних моделей за допомогою відомих та розроблених методів будемо використовувати критерій помилки моделі на тестових даних E_t . Порівнюючи результати різних методів, наведені у таблиці, відзначимо, що розроблений стохастичний метод синтезу дерев розв'язків дозволив підвищити рівень узагальнення даних за допомогою синтезованої діагностичної моделі на 69,9 % у порівнянні з методом CART ($E_t = 0,028$ та $E_t = 0,093$, відповідно $\Delta E_t = |0,093 - 0,028| / 0,093 = 69,9\%$), на 61,1 % у порівнянні з методом C4.5 та на 9,7% у порівнянні з еволюційним методом [292].

Скорочення часу пошуку ($t = 7,31$ с) на 1,5–51,6% (до двох разів) у порівнянні з відомими методами ($t = 15,12$ для методу CART, $t = 14,82$ для методу C4.5, $t = 7,42$ для еволюційного методу [292]) забезпечено за рахунок формування на етапі ініціалізації запропонованого методу множини деревоподібних структур, що характеризуються простою ієрархією і невисокою помилкою розпізнавання, а також створення в процесі пошуку нових множин рішень з урахуванням інформації про значущість ознак та інтерпретовність генерованих дерев.

Відзначимо, що низьке значення критерію узагальнення рішень $Gener = 0,215$ також свідчить про високі узагальнювальні здібності синтезованого дерева.

Дерева, синтезовані за допомогою еволюційного [292] і запропонованого стохастичного методів є більш гіллястими (значення критеріїв

складають $Br = 0,65$ і $Br = 0,62$, відповідно) у порівнянні з деревами, побудованими за допомогою методів CART [133–141] і C4.5 [133–141] ($Br = 0,37$ і $Br = 0,4$), що свідчить про більш компактне розміщення вузлів та більш високу інтерпретовність синтезованого дерева.

Для порівняння інтерпретовності діагностичних моделей на основі дерев розв'язків, синтезованих за допомогою різних методів, будемо використовувати кількість вузлів $N_{node}(\chi_k)$ синтезованого дерева χ_k , оскільки різні критерії інтерпретовності в тій чи іншій мірі пов'язані саме з цією оцінкою.

Порівнюючи значення оцінок $N_{node}(\chi_k)$ для різних методів, можна зробити висновок, що запропонований стохастичний метод синтезу дерев розв'язків дозволив підвищити рівень інтерпретовності синтезованої діагностичної моделі на 23,2 % у порівнянні з методом CART ($N_{node} = 73$ та $N_{node} = 95$, відповідно $\Delta N_{node} = |95 - 73| / 95 = 23,2\%$), на 29,1 % у порівнянні з методом C4.5 та на 12% у порівнянні з еволюційним методом [292].

Важливо відзначити, що аналогічні результати були отримані також при розв'язанні задачі медичного діагностування хронічного обструктивного бронхіту за даними клінічних лабораторних досліджень [292].

Таким чином, результати порівняльного аналізу показали, що розроблений стохастичний метод синтезу дерев розв'язків дозволяє підвищити швидкість побудови діагностичних моделей на основі дерев розв'язків (до двох разів) у порівнянні з відомими методами, а також збільшити рівні інтерпретовності (на 12–29,1%) та узагальнення даних (на 9,7–69,9%) синтезованих моделей. Запропонований стохастичний метод синтезу дерев розв'язків не уступає по якості побудови деревоподібних моделей прийняття рішень відомим методам, і забезпечує можливість побудови дерева розв'язків з невеликою кількістю структурних елементів і прийнятною точністю розпізнавання.

Виконаємо експериментальне дослідження запропонованого стохастичного методу видобування чисельних асоціативних правил. Для цього

порівняємо його з відомими методами видобування чисельних асоціативних правил – FARM (Fuzzy Association Rule Mining) [349], FWARМ (Fuzzy Weighted Association Rule Mining) [350], методом синтезу асоціативних правил з врахуванням значущості ознак, запропонованому в [351]. Важливо відзначити, що розв’язувалися задачі видобування правил з чисельних баз транзакцій, тому застосування відомих методів (Apriori, SETM і ін.) було ускладнено, оскільки такі методи дозволяють видобувати асоціативні правила з бінарних даних. За допомогою запропонованого і відомих методів вирішувалися задачі прийняття рішень у технічному діагностуванні авіадвигунів, зокрема задача виявлення прихованих залежностей між параметрами авіадвигунів при різних режимах випробувань.

У процесі випробувань авіадвигунів контролюються параметри, що характеризують якість їхньої роботи при різних режимах [348]. Проте процес випробувань є досить тривалим за часом, вимагає значної кількості випробувань (циклів, іспитів) кожного виробу при різних режимах, а також істотних матеріальних витрат (палива) на випробування в кожному циклі. При цьому устаткування для проведення випробувань має обмежену пропускну здатність. Тому актуальним є скорочення часу, а також кількості режимів випробувань авіадвигунів, що дозволить скоротити матеріальні витрати на їхнє виготовлення. Для цього необхідно виявити залежності між характеристиками двигунів, вимірюваними чи встановлюваними у процесі випробувань ($p_1 - p_9$), та параметрами й режимами випробувань ($p_{10} - p_{14}$). Виявлення таких залежностей дозволить скоротити кількість режимів випробувань та, відповідно, знизити матеріальні затрати на проведення діагностування.

Вибірка даних містить значення характеристик, що вимірюються у процесі випробувань для чотирьох режимів випробувань (зліт, номінальний, перший крейсерський, другий крейсерський) [348]: p_1 – кількість оборотів турбіни компресора, об/хв; p_2 – температура газу перед турбіною, °С; p_3 – витрата газу через турбіну; p_4 – температура на вході в двигун, °С; p_5 – кількість ступенів; p_6 – кут встановлення лопаток вхідного направляючого

апарату; p_7 – приведена потужність; p_8 – витрата повітря; p_9 – ступінь стиску повітря; p_{10} – адіабатичний тиск, мм; $p_{11} - p_{14}$ – прохідні перетини соплового апарату першої, другої, третьої і четвертої ступенів, відповідно.

Відзначимо, що деякі дані внаслідок людського фактора, збоїв і відмовлень вимірювального устаткування та інших причин у вибірці не зафіксовано. Крім того, для деяких авіадвигунів існує інформація про випробування лише при деяких режимах. Наявність пропущених значень у вихідній вибірці S обумовлює доцільність застосування апарату асоціативних правил для виявлення прихованих залежностей у даних.

Результати експериментів по дослідженню різних методів видобування асоціативних правил при вирішенні задачі виявлення прихованих залежностей між параметрами авіадвигунів при різних режимах випробувань наведено в таблиці 7.2. Вихідну вибірку даних наведено у табл. А.2. Як критерій оцінювання якості асоціативних правил при дослідженні стохастичного методу видобування чисельних асоціативних правил використовувалася інформативність правила $VI(A_k)$, оскільки такий критерій дозволяє враховувати вірогідність правила та індивідуальну інформативність V_m кожної ознаки p_m , що входить у його антецедент P_k .

Таблиця 7.2 – Результати експериментів з видобування асоціативних правил

Метод	supp, %	conf, %	confG, %	N_A	$N(P_k)$	VS	VC	VM	VI
FARM [349]	6,2	82,3	73,7	121	6,78	0,52	3,05	10,87	6,63
FWARM [350]	5,4	87,7	77,5	87	6,32	0,55	3,09	12,26	7,73
Метод синтезу асоціативних правил з врахуванням значущості ознак (МСАПВЗО) [351]	4,7	91,2	82,1	82	6,46	0,54	3,92	12,71	9,40
Стохастичний метод видобування чисельних асоціативних правил [281]	4,2	90,1	89,2	133	5,06	0,64	3,61	17,63	14,1

У таблиці наведено середні значення параметрів supp , conf , conf , $N(P_k)$, VS , VC , VM , VI , що характеризують якість видобутих асоціативних правил.

Як видно, значення середньої підтримки supp виявлених за допомогою запропонованого методу асоціативних правил трохи нижче ($\text{supp} = 4,2$), ніж у наборів асоціативних правил, видобутих відомими методами FARM [349] ($\text{supp} = 6,2$), FARM [350] ($\text{supp} = 5,4$), МСАПВЗО [351] ($\text{supp} = 4,7$), оскільки запропонований метод дозволив крім достовірних правил, що часто зустрічаються, також виявити закономірності на основі наборів, що рідко зустрічаються. Про це також свідчить велика кількість видобутих правил N_A (у запропонованого методу $N_A = 133$, в інших методів кількість видобутих правил менше: $N_A = 121$ для FARM, $N_A = 87$ для FARM, $N_A = 82$ для МСАПВЗО).

Значення середньої вірогідності conf виявлених правил на основі розробленого стохастичного методу видобування чисельних асоціативних правил ($\text{conf} = 90,1$) є вищим, ніж у методів FARM [349] ($\text{conf} = 82,3$) і FARM [350] ($\text{conf} = 87,7$). Це свідчить про те, що запропонований метод дозволяє виявляти більш достовірні правила (це досягається за рахунок використання стохастичного перебору різних сполучень антецедентів і консеквентів асоціативних правил, а також врахування апріорної інформації про значущість термів і ознак). У порівнянні з методом МСАПВЗО значення критерію conf є дещо нижчим ($\text{conf} = 90,1$ і $\text{conf} = 91,2$, відповідно), оскільки при проведенні експериментів як критерій оцінювання асоціативних правил у запропонованому стохастичному методі видобування чисельних асоціативних правил використовувався критерій інформативності правил $VI(A_k)$, що враховує не тільки вірогідність conf , але й інші характеристики.

Запропонований стохастичний метод дозволив синтезувати базу $A = \{A_1, A_2, \dots, A_{N_A}\}$ асоціативних правил $A_k : P_k \rightarrow T_k$, що характеризується більш високою середньою загальною вірогідністю правил ($\text{confG} = 89,2$ у порівнянні з $\text{confG} = 73,7$, $\text{confG} = 77,5$ і $\text{confG} = 82,1$ для методів FARM,

FWARM і МСАПВЗО, відповідно), враховує частоту виконання не тільки позитивних умов $P_k \rightarrow T_k$, але і негативних умов $\overline{P_k} \rightarrow \overline{T_k}$ виконання правил.

Оцінимо за допомогою критерію $\text{confG}(A_k)$ рівень узагальнення даних діагностичними моделями $A_k : P_k \rightarrow T_k$ на основі асоціативних правил, синтезованими різними методами. Як видно значення загальної вірогідності $\text{confG}(A_k)$ правил як критерій, що враховує частоту виконання як позитивних так і негативних умов правил, у моделі, синтезованої за допомогою запропонованого методу ($\text{confG} = 89,2$), є вищим на 8,6–21 % у порівнянні з моделями, побудованими на основі відомих методів (значення критерію confG від 73,7 до 82,1).

Більш прийнятні значення критеріїв $N(P_k)$, VS , VC , VM , VI (наприклад, середня складність $VS(A_k)$ видобутих за допомогою розробленого методу правил склала $VS = 0,64$ в порівнянні з $VS = 0,52$, $VS = 0,55$ і $VS = 0,54$ для FARM, FWARM і МСАПВЗО, відповідно) у запропонованого методу обумовлені також застосуванням інформативності $VI(A_k)$ (критерії $N(P_k)$, VS , VC , VM і VI є взаємозалежними) в якості критерію оцінювання асоціативних правил, що видобуваються. Це дозволило забезпечити видобування більшої кількості N_A асоціативних правил $A_k : P_k \rightarrow T_k$, які є більш простими та інтерпретовними (характеризуються меншою кількістю умов $N(P_k)$ в антецеденті P_k), а також більш достовірними й інформативними (характеризуються більш прийнятними значеннями критеріїв conf , VC , VM , VI) у порівнянні з правилами, виявленими за допомогою відомих методів.

Оцінимо здатність методів видобувати інтерпретовні набори правил за допомогою критерію $N(P_k)$, що характеризує середню кількість умов в антецеденті правила. Як видно, запропонований стохастичний метод видобування чисельних асоціативних правил дозволив синтезувати набір правил $A = \{A_1, A_2, \dots, A_{N_A}\}$ з середньою кількістю умов в антецеденті

$N(P_k) = 5,06$, що є на 20–25,4 % меншим у порівнянні зі значенням аналогічного критерію, розрахованого для наборів правил, видобутих за допомогою інших методів ($N(P_k) = 6,32$ для методу FARM, $N(P_k) = 6,78$ для методу FARM, $N(P_k) = 6,46$ для МСАПВЗО).

Таким чином виконано порівняння запропонованого стохастичного методу видобування чисельних асоціативних правил з відомими аналогами. Визначено, що запропонований стохастичний метод дозволяє синтезувати діагностичні моделі на основі асоціативних правил з більш високими рівнями узагальнення даних (вище на 8,6–21 %) та інтерпретовності (вище на 20–25,4 %). Виявлено, що розроблений метод видобування чисельних асоціативних правил дозволяє обробляти чисельну інформацію з пропущеними значеннями, не здійснювати істотну кількість проходів по заданій базі транзакцій, виявляти правила з високим рівнем вірогідності та інших критеріїв оцінювання їхньої якості.

Для дослідження запропонованого методу синтезу продукційних правил на основі негативного відбору розв'язувалася задача діагностування лопаток газотурбінних авіаційних двигунів [51, 294, 348]. Лопатки характеризувалися усередненими значеннями спектрів потужності загасаючих коливань після ударного порушення, що використовувалися як вхідні ознаки. Експертно було визначено класи якості лопаток: придатні (кондиційні) і дефектні (некондиційні). Кожна лопатка була описана 10240 ознаками, що характеризували усереднений спектр потужності загасаючих коливань у частотному діапазоні до 25 кГц з дискретизацією за частотою 2,44 Гц [51], значення спектрів характеризували усереднений частотний склад вільних згасаючих коливань у вигляді спектральної щільності потужності амплітуд віброприскорення. Для скорочення простору пошуку на основі цих ознак було отримано штучні ознаки-згортки [3, 51], у результаті чого створено набір P , що складається зі штучних 80 ознак.

Отримана вибірка спостережень $S = \langle P, T \rangle$, вочевидь, не характеризується статистичною репрезентативністю, оскільки не відображає реального розподілу частот класів (у генеральній сукупності придатних лопаток суттєво більше, ніж дефектних). При цьому дефектні лопатки ($t_q = t'_1$) у наявній вибірці S представляють типові випадки некондиційності, що забезпечує топологічну репрезентативність дефектних лопаток у вибірці. А всі можливі випадки класу придатних ($t_q = t'_0$) неможливо представити у вибірці з практичної точки зору. Тому виникає необхідність на основі наявної вибірки $S = \langle P, T \rangle$ з нерівномірним розподілом екземплярів по класах побудувати діагностичну модель, що дозволяє виконувати технічне діагностування лопаток авіадвигунів на основі заданого набору вимірювань. Вибірка $S = \langle P, T \rangle$ (табл. А.3) містила інформацію про екземпляри, що характеризують некондиційні лопатки, та інформацію про придатні вироби.

Запропонований метод синтезу продукційних правил на основі негативного відбору порівнювався з існуючими методами негативного відбору, що синтезують набір детекторів тільки на основі «своїх» екземплярів вибірки $S_1 \subseteq S$. Тому за допомогою запропонованого методу задача діагностування лопаток газотурбінних авіаційних двигунів розв'язувалася два рази: з використанням підвибірки ($S_1 \subseteq S$), що містить інформацію тільки про некондиційні екземпляри («своїх»), та з використанням усієї вихідної вибірки $S = \langle P, T \rangle$.

Результати експериментів з порівняння запропонованого методу з іншими методами негативного відбору наведено в табл. 7.3, де N_{it} – кількість ітерацій роботи методу; t – час роботи методу, с; E – помилка розпізнавання на навчальних даних ($S = \langle P, T \rangle$); E_t – помилка розпізнавання на тестових даних; $P_{t, t_q=t'_1/t_q=t'_0}$ – ймовірність помилки віднесення до класу «своїх» ($t_q = t'_1$) за

умови, що екземпляр реально відноситься до класу «чужих» ($t_q = t'_0$); $P_{t,t_q=t'_0/t_q=t'_1}$ – ймовірність помилки віднесення до класу «чужих» ($t_q = t'_0$) за умови, що екземпляр реально відноситься до класу «своїх» ($t_q = t'_1$).

Ймовірності $P_{t,t_q=t'_1/t_q=t'_0}$ та $P_{t,t_q=t'_0/t_q=t'_1}$ обчислюються за такими формулами:

$$P_{t,t_q=t'_1/t_q=t'_0} = \frac{N_{t,t_q=t'_1/t_q=t'_0}}{N_{t,t_q=t'_0}},$$

$$P_{t,t_q=t'_0/t_q=t'_1} = \frac{N_{t,t_q=t'_0/t_q=t'_1}}{N_{t,t_q=t'_1}},$$

де $N_{t,t_q=t'_1/t_q=t'_0}$ – кількість екземплярів тестової вибірки, що розпізнані як «свої» ($t_q = t'_1$), але реально відносяться до класу «чужих» ($t_q = t'_0$);

$N_{t,t_q=t'_0}$ – кількість екземплярів тестової вибірки, що відносяться до класу «чужих» ($t_q = t'_0$);

$N_{t,t_q=t'_0/t_q=t'_1}$ – кількість екземплярів тестової вибірки, що розпізнані як «чужі» ($t_q = t'_0$), але реально відносяться до класу «своїх» ($t_q = t'_1$);

$N_{t,t_q=t'_1}$ – кількість екземплярів тестової вибірки, що відносяться до класу «своїх» ($t_q = t'_1$).

Як тестова вибірка S_t використовувалася вибірка, що містить інформацію 261 екземпляр придатних виробів, які відносяться до класу $t_q = t'_0$, і 12 екземплярів некондиційних виробів, що відносяться до класу $t_q = t'_1$).

Таблиця 7.3 – Результати експериментів по дослідженню методів негативного відбору

Метод	N_{Ab}	N_{it}	t	E	$P_{t,t_q=t'_1/t_q=t'_0}$	$P_{t,t_q=t'_0/t_q=t'_1}$	E_t
Метод з цензуруванням [177]	207	50	27,3	0,070	0,126	0,333	0,136
Модель V-Detector [178, 179]	41	50	24,1	0,035	0,069	0,250	0,077
Метод з маскуваннюм детекторів [180]	19	14	13,2	0,018	0,054	0,083	0,055
Метод синтезу продукційних правил на основі негативного відбору МСППОНВ [284] (використовувалася вибірка $S_1 \subseteq S$)	20	12	12,1	0,026	0,038	0	0,037
Метод синтезу продукційних правил на основі негативного відбору МСППОНВ [284] (використовувалася вибірка $S = \langle P, T \rangle$)	31	19	13,7	0,009	0,011	0	0,011

Як видно з таблиці, прийнятне значення помилки розпізнавання E забезпечив метод з маскуванням детекторів [180] ($E = 0,018$) і запропонований метод синтезу продукційних правил на основі негативного відбору (МСППОНВ). Низькі значення помилки розпізнавання зазначених методів забезпечувалися за рахунок широкого покриття синтезованими детекторами області «своїх» екземплярів вибірки $S_1 \subseteq S$. При цьому помилка розпізнавання запропонованого методу МСППОНВ, що синтезував набір детекторів на основі екземплярів усіх класів вибірки $S = \langle P, T \rangle$, забезпечив більш прийнятні результати ($E = 0,009$) у порівнянні з набором детекторів, синтезованим тільки з використанням екземплярів класу «своїх» $S_1 \subseteq S$ ($E = 0,026$). Менш

прийнятні значення помилки розпізнавання E показали метод з цензуруванням [177] ($E = 0,070$) і модель V-Detector [178, 179] ($E = 0,035$), що свідчить про недостатність покриття синтезованими детекторами області «своїх» екземплярів $S_1 \subseteq S$.

За результатами експериментів видно, що при використанні методу з цензуруванням [177] і моделі V-Detector [178, 179] генерується найбільша кількість детекторів N_{Ab} ($N_{Ab} = 207$ і $N_{Ab} = 41$, відповідно), що негативно впливає на час навчання t і витрати обчислювальних ресурсів комп'ютера. Метод з маскуванням детекторів [180] і запропонований метод синтезу продукційних правил на основі негативного відбору (при використанні вибірки $S_1 \subseteq S$) згенерували суттєво меншу кількість детекторів ($N_{Ab} = 19$ і $N_{Ab} = 20$, відповідно, що приблизно в 2–10 разів менше у порівнянні з результатами методів [177–179]), що свідчить про більш ефективну роботу цих методів та більшу інтерпретовність синтезованих діагностичних моделей на основі правил. Зокрема, метод МСППОНВ використовує апріорну інформацію про значущість ознак на початковому етапі та виключає з подальшого розгляду малозначущі і надлишкові ознаки, що дозволяє скоротити простір пошуку та створювати набори з невеликої кількості детекторів на основі високоінформативних ознак, які характеризуються високими апроксимаційними й узагальнювальними властивостями.

Результати експериментів показали, що запропонований синтезу продукційних правил на основі негативного відбору забезпечив побудову діагностичної моделі у вигляді продукційних правил за менший час ($t = 12,1$ для вибірки $S_1 \subseteq S$) у порівнянні з іншими методами ($t = 13,2$ для методу з маскуванням детекторів [180], $t = 24,1$ для моделі V-Detector [178, 179] та $t = 27,3$ для методу з цензуруванням [177]), таким чином дозволивши прискорити процес синтезу моделі на 8,3–55,7%. Це обумовлено

використанням апріорної інформації та виключенням малозначущих і надлишкових ознак з вибірки, що дозволило скоротити простір пошуку.

Для аналізу узагальнювальних властивостей досліджуваних методів використовувалися критерії E_t , $P_{t,t_q=t'_1/t_q=t'_0}$ і $P_{t,t_q=t'_0/t_q=t'_1}$, що характеризують помилки розпізнавання й імовірності прийняття помилкових рішень на тестових даних. Як видно з табл. 7.3, помилки розпізнавання на тестових даних E_t у моделей, синтезованих за допомогою запропонованого методу МСППОНВ, є суттєво нижчими помилок моделей, побудованих за допомогою відомих методів [177–180] ($E_t = 0,136$, $E_t = 0,077$, $E_t = 0,055$ для методів [177], [178, 179] і [180], відповідно). Це пояснюється використанням в якості критерію оцінювання кандидатів у детектори характеристик $G(Ab_k)$, що дозволяють оцінювати здатність детекторів до узагальнення даних. Запропонований метод синтезу продукційних правил на основі негативного відбору дозволив досягти рівнів помилки $E_t = 0,037$ (при використанні частини вибірки $S_1 \subseteq S$, значення критерію E_t є нижчим на 32,7–72,8 % у порівнянні з відомими методами [177–180]) і $E_t = 0,011$ (при використанні повної вибірки $S = \langle P, T \rangle$).

Важливо відзначити, що в силу специфіки розв'язуваної задачі діагностування лопаток газотурбінних авіаційних двигунів дуже високу ціну має імовірність помилки $P_{t,t_q=t'_0/t_q=t'_1}$ віднесення до класу «чужих» ($t_q = t'_0$, придатних) за умови, що екземпляр реально відноситься до класу «своїх» ($t_q = t'_1$, непридатних). Це обумовлено тим, що віднесення дефектних лопаток авіадвигунів до класу придатних може коштувати людських життів. Як видно з табл. 7.3, запропонований метод МСППОНВ, на відміну від існуючих, на тестових даних показав нульовий рівень імовірності помилки $P_{t,t_q=t'_0/t_q=t'_1}$, що свідчить про його високу ефективність для розв'язання подібних задач. Нульовий рівень імовірності помилки $P_{t,t_q=t'_0/t_q=t'_1}$ при використанні запропонованого методу обґрунтовується:

– високим рівнем покриття типових екземплярів класу $t_q = t'_1$ за допомогою згенерованого набору детекторів $AB = \{Ab_1, Ab_2, \dots, Ab_{N_{Ab}}\}$, отриманого з використанням апріорної інформації про значущість ознак;

– високими узагальнювальними властивостями синтезованого набору детекторів, що обумовлено застосуванням в якості критерію оцінювання детекторів характеристик (2.47) і (2.48), які дозволяють оцінювати здатність детекторів Ab_k до узагальнення даних.

Також виконано порівняння запропонованого методу з іншими методами, що дозволяють вирішувати задачі діагностування та розпізнавання образів. Для цього розв'язувалася описана вище задача діагностування лопаток газотурбінних авіаційних двигунів. Досліджувалися властивості та характеристики таких діагностичних моделей:

– модель у вигляді набору продукційних правил, синтезованих за допомогою запропонованого методу на основі негативного відбору з урахуванням інформативності ознак;

– нейромережева модель прямого поширення, що складає з трьох шарів нейронів, побудована на основі методу зворотного поширення помилки. На першому шарі нейромережі знаходилося п'ять нейронів, на другому – три нейрони, на третьому – один нейрон. Нейрони першого та другого шару мали логістичну сигмоїдну функцію активації, третього – граничну (порогову) функцію активації;

– модель у вигляді набору детекторів, побудована за допомогою методу негативного відбору з маскуванням детекторів [180].

При цьому використовувалася вся навчальна вибірка $S = \langle P, T \rangle$ для побудови першої та другої моделей, і частина вибірки ($S_1 \subseteq S$) для побудови моделі на основі набору детекторів за допомогою методу негативного відбору з маскуванням, оскільки даний метод допускає роботу з екземплярами тільки одного класу.

Результати порівняння різних моделей при розв'язанні задачі діагностування лопаток газотурбінних авіаційних двигунів [294, 348] наведено в табл. 7.4, де N_{param} – критерій, що визначає параметричну складність моделі. Критерій N_{param} розраховувався як кількість параметрів моделі: загальна кількість параметрів $Ab_{km\min}$ і $Ab_{km\max}$ в моделях на основі продукцій і на основі набору детекторів [180], загальна кількість параметрів, що налаштовуються (вагових коефіцієнтів) – у нейромережевої моделі.

Таблиця 7.4 – Результати порівняння різних моделей

Модель	N_{param}	E	$P_{t,t_q=t'_1/t_q=t'_0}$	$P_{t,t_q=t'_0/t_q=t'_1}$	E_t
Модель у вигляді набору продукційних правил, синтезованих за допомогою запропонованого методу [284]	652	0,009	0,011	0	0,011
Нейромережева модель прямого поширення [80]	427	0,018	0,065	0,167	0,070
Модель у вигляді набору детекторів, побудована за допомогою методу негативного відбору з маскуванням детекторів [180]	804	0,018	0,054	0,083	0,055

З таблиці видно, що кількість параметрів N_{param} моделі у вигляді набору продукційних правил, синтезованих за допомогою запропонованого методу, є меншою ($N_{param} = 652$), ніж у аналогічній моделі, побудованій за допомогою методу негативного відбору з маскуванням детекторів [180] ($N_{param} = 804$). Це обґрунтовується тим, що при використанні запропонованого методу середній

розмір згенерованих детекторів є меншим, оскільки в процесі негативного відбору використовується апріорна інформація про значущість ознак. Це дозволяє виявляти та виключати з подальшого розгляду малозначущі і надлишкові ознаки, що ускладнюють процес синтезу діагностичних моделей і знижують їх інтерпретовність. Таким чином, порівняння значень різних критеріїв, наведених у таблиці 7.4, показує, що модель у вигляді набору продукційних правил, синтезованих за допомогою запропонованого методу МСППОНВ, є більш простою та зрозумілою в порівнянні з моделлю, створеною за допомогою методу [180]. Апроксимаційні та узагальнювальні властивості моделі, синтезованої на основі методу МСППОНВ, також є більш високими, про що свідчать значення критеріїв E , E_t , $P_{t,t_q=t'_1/t_q=t'_0}$ і $P_{t,t_q=t'_0/t_q=t'_1}$.

Порівняння моделі на основі методу МСППОНВ і нейромережевої моделі дозволяє зробити висновок про те, що модель, побудована за допомогою запропонованого методу, характеризується більш високими узагальнювальними й апроксимаційними властивостями (критерії E , E_t , $P_{t,t_q=t'_1/t_q=t'_0}$ і $P_{t,t_q=t'_0/t_q=t'_1}$). Однак, кількість параметрів N_{param} моделі на основі методу МСППОНВ ($N_{param} = 652$) є трохи більшою, ніж у нейромережевої моделі ($N_{param} = 427$). Це пояснюється тим, що нейромережева модель представляється у вигляді множини нейронів, які пов'язані між собою певним чином і характеризуються ваговими коефіцієнтами як налаштовуваними параметрами. А кожен нейрон, по суті, відповідає деякій функції багатьох аргументів. При цьому така модель є досить складною для сприйняття людиною. Не дивлячись на більш високе значення критерію N_{param} , модель у вигляді набору продукційних правил, синтезованих за допомогою запропонованого методу, є більш інтерпретовною у порівнянні з нейромережевою моделлю, оскільки продукційні правила вигляду «Якщо умова, то дія» є значно більш зрозумілими та зручними для сприйняття

людиною у порівнянні з набором коефіцієнтів, які відображають ступінь зв'язків нейронів у нейромережевій моделі.

Таким чином, результати експериментів показали, що запропонований метод за рахунок використання апріорної інформації та виключення малозначущих і надлишкових ознак з вибірки дозволяє скорочувати простір пошуку і час виконання методу (на 8,3–55,7 % у порівнянні з відомими аналогами [177–180]), а також синтезувати діагностичні моделі у вигляді набору детекторів з високими апроксимаційними й узагальнювальними властивостями (на 32,7–72,8 % вищими у порівнянні з відомими методами [177–180]). Крім того розроблений метод за рахунок підвищення узагальнювальних властивостей синтезованих моделей шляхом скорочення кількості детекторів і умов антецедентів підвищує інтерпретовність моделі (у 2–10 разів у порівнянні з методами [177–179]), скорочує її розмірність і, отже, обсяг використовуваної пам'яті.

Для перевірки ефективності запропонованого паралельного методу видобування продукційних правил (ПМВПП) розв'язувалася практична задача розпізнавання автотранспортних засобів. Системи відеоспостереження за автомобільними трасами в ряді країн світу передбачають різні швидкісні обмеження для різних типів транспортних засобів (легкові, вантажні автомобілі, автобуси, мотоцикли та ін.). Для визначення порушників і стягування штрафів відомі системи припускають установку механічних ваг під дорожнім полотном і зважування кожного транспортного засобу. Такі системи не є мобільними, є вкрай дорогими і як наслідок, дуже обмежено застосовними через неможливість створення великої кількості таких систем. Проте, людина може визначити тип транспортного засобу, як у динаміці, так і на одиничній фотографії. Тому виникає необхідність розв'язання задачі визначення типу транспортного засобу по отриманому зображенню за допомогою камер фото- або відеофіксації, встановлених на автотрасах [294].

Подібного роду об'єкти характеризуються надзвичайно великою варіативністю, мають різні габарити і кути зйомки щодо камери. Тому для автоматизації процесу розпізнавання типів транспортних засобів необхідно будувати розпізнавальні моделі по наявних вибірках даних великого обсягу. Для цього доцільно використовувати нейро-нечіткі мережі, що характеризуються високими апроксимаційними й узагальнювальними здібностями. Однак при обробці великих обсягів даних синтезовані моделі є, як правило, дуже громіздкими, вимагають великих ресурсів пам'яті та значних часових витрат на розпізнавання з їх допомогою, що істотно ускладнює їхнє застосування на практиці при використанні на невеликих пристроях, встановлених на дорогах.

Тому до синтезу нейро-нечітких розпізнавальних моделей при обробці великих обсягів даних у цій роботі пропонується виділити набір продукційних правил за допомогою запропонованого методу. Потім використовувати набір видобутих правил для побудови нейро-нечіткої моделі.

В експериментах використовувалася вибірка даних (табл. А.4), що містила інформацію про зображення, знятих у тонах сірого. За допомогою системи [352] на зображеннях виявлялися регіони інтересу з автомобілем, що цензурувалися вручну людиною (був визначений клас автомобіля: 0 – не розпізнано, 1 – мотоцикліст, 2 – легковий, 3 – вантажне авто, 4 – автобус, 5 – мінівен чи мікроавтобус) і відображалися на сенсорну матрицю розмірністю 128×128 . Для кожного типу транспортного засобу будувалася своя розпізнавальна модель, яка на виході давала 0 чи 1 (відноситься розпізнаваний засіб до даного типу чи ні).

Експерименти було виконано по декілька разів на одному, двох, чотирьох, восьми і шістнадцяти ядрах задіяних процесорів. На GPU задавалася кількість задіяних потоків, і вимірявся час виконання методу за допомогою

вбудованих у пакет CUDA функцій [152]. Експерименти було проведено на 60, 80, 100, 120, 140, 160, 180, 200 і 240 потоках.

На рис. А.1 та А.2 наведено усереднені часові витрати на виконання запропонованого паралельного методу видобування продукційних правил на кластерах і на графічних процесорах. Для зручності сприйняття графіків, використаний час наведено у хвилинах у залежності від кількості задіяних ядер або потоків GPU.

Як видно з рис. А.1, А.2 запропонований метод добре масштабується на кластерах і на графічних процесорах та дозволяє істотно скоротити часові витрати на видобування продукційних правил. При цьому розходження в продуктивності використаних кластерів і графічних процесорів обумовлені архітектурними особливостями устаткування (кількість ядер, тактова частота, між'ядерні зв'язки, пропускна здатність каналів зв'язку). Графіки прискорення обчислювального процесу на кластерах і на GPU наведено на рис. А.3 та рис. А.4, відповідно. Прискорення для GPU розраховано відносно реалізації на одному ядрі кластера IPME.

З рис. А.3 і А.4 видно, що прискорення обчислювального процесу зростає нелінійно зі збільшенням кількості ядер і потоків GPU. Для встановлення причини нелінійного росту прискорення було обміряно комунікаційні витрати, а саме: пересилання між ядрами процесорів і синхронізація потоків. Отримані результати наведено на рис. А.5 та А.6.

Для кластерів частка комунікаційних витрат в обчислювальному процесі зростає зі збільшенням кількості задіяних ядер. Відмінності між кластерами обумовлені розходженням середовищ передачі даних у цих кластерах. Чим швидшим і менш латентним є середовище передачі даних, тим менше часу потрібно на пересилання і тим меншою є частка комунікаційних витрат.

Для GPU частка комунікаційних витрат залежить насамперед від архітектури обладнання. Так, для GTX285+ починаючи з 160-ти задіяних

потоків зростає частка пересилань і синхронізацій. Для GTX960, де кількість потоків і пропускна здатність шин є істотно більшими, частка комунікаційних витрат починає підвищуватися при кількості задіяних потоків більше 200.

Графік ефективності кластерів, на яких виконувалася реалізація запропонованого методу, наведено на рис. А.7. З рисунку видно, що системи продемонстрували прийнятну ефективність у реалізації запропонованого методу.

Таким чином, застосування кластерів і графічних процесорів для реалізації запропонованого методу є доцільним, оскільки це істотно знижує затрачуваний на виконання методу час без зниження точності рішення. Метод добре масштабується в паралельних системах, при цьому сучасний графічний процесор з SIMD-архітектурою дозволяє досягти продуктивності, порівнянної з чотирма ядрами кластера.

Для порівняння різних методів видобування продукційних правил розв'язувалися також інші задачі діагностування та розпізнавання. У таблиці 7.5 наведено чисельні характеристики різних методів видобування продукційних правил для побудови нейро-нечітких моделей. У силу стохастичності розглянутих методів у таблиці 7.5 наведено усереднені результати. При вирішенні кожної задачі виконувався синтез нейро-нечіткої діагностичної моделі за допомогою методу зворотного поширення помилки [241, 242] на основі всієї заданої навчальної $S = \langle P, T \rangle$ вибірки (назви стовпців у таблиці ВР). Крім того, виконувався синтез нейро-нечіткої моделі [292, 324] на основі видобутої множини продукційних правил RB за допомогою методів на основі дерев розв'язків [276], асоціативних правил [282], негативного відбору [283] (назви стовпців у таблиці DT, AR, NS, відповідно), а також за допомогою запропонованого паралельного методу з використанням CPU (16 вузлів) і GPU (200 потоків).

Таблиця 7.5 – Чисельні характеристики методів видобування продукційних правил для побудови нейронечітких моделей

№	Назва	Задача					Помилка моделі (на навчальних даних E_t)						Час t , с					
		M	Q	Ознаки	Вихідний параметр	BP	DT	AR	NS	CPU 16 вузлів	GPU 200 потоків	BP	DT	AR	NS	CPU 16 вузлів	GPU 200 потоків	
1	Розпізнавання автотранспортних засобів [352]	16384	10000	цілі	бінарний	0,009	0,012	0,017	0,044	0,008	0,010	27191,2	8295,1	7409,8	3981,4	1234,8	3244,8	
2	Діагностування якості життя хворих на хронічний обструктивний бронхіт від поєднання використовуваних лікарських засобів [292]	95	1023	бінарні	бінарний	0,011	0,018	0,041	0,012	0,011	0,012	18,7	5,1	3,95	4,12	0,87	2,1	
3	Діагностування лопаток газотурбінних авіадвигунів за спектрами вільних згасаючих коливань [292, 348]	10240	318	дійсні	бінарний	0,007	0,017	0,032	0,011	0,008	0,009	571,9	178,4	218,7	119,2	31,2	77,1	
4	Розпізнавання типів рослин по спектральним точкам [292]	55	248	дійсні	бінарний	0,034	0,039	0,063	0,032	0,031	0,030	5,2	1,47	1,62	1,08	0,27	0,64	
5	Побудова моделі якості кондитерських виробів [293]	43	956	дійсні (є дані з пропусками)	дійсний	0,039	0,047	0,032	0,141	0,029	0,031	39,1	13,16	10,33	19,32	2,54	6,71	

З таблиці 7.5 видно, що величина помилки моделі E , синтезованої на основі продукційних правил, видобутих за допомогою запропонованого паралельного методу (для задачі розпізнавання автотранспортних засобів [352] за допомогою CPU і GPU $E = 0,008$ і $E = 0,010$, відповідно), є співставною з величиною помилки моделі, побудованої на основі повної вибірки даних $S = \langle P, T \rangle$ ($E = 0,009$). Аналогічні значення отримані і для інших практичних задач. Відзначимо, що ефективність використання інших методів видобування продукційних правил істотно залежить від особливостей навчальної вибірки $S = \langle P, T \rangle$. Так, для задачі з бінарними ознаками і бінарним вихідним параметром (діагностування якості життя хворих хронічним обструктивним бронхітом від поєднання використовуваних лікарських засобів [292]) найбільш ефективним виявився метод видобування продукційних правил на основі негативного відбору ($E = 0,012$).

Запропонований паралельний метод також забезпечив досягнення високого рівня точності ($E = 0,011$ для CPU і $E = 0,012$ для GPU), що обумовлено видобуванням правил на основі різних інтелектуальних моделей, що узагальнюють задані вибірки даних у вигляді моделей на основі негативного відбору, дерев розв'язків і асоціативних правил. Експерименти показали, що для задач з дійсними значеннями ознак ефективним є видобування правил на основі дерев розв'язків ($E = 0,017$ для задачі діагностування лопаток газотурбінних авіадвигунів по спектрах вільних загасаючих коливань [292, 348] і $E = 0,039$ для задачі розпізнавання типів рослин [292]). Запропонований паралельний метод при розв'язанні зазначених задач забезпечив більш прийнятні значення помилки розпізнавання ($E = 0,008$ для CPU і $E = 0,009$ для GPU при розв'язанні задачі 3; $E = 0,031$ для CPU і $E = 0,030$ для GPU при розв'язанні задачі 4), що також обумовлено узагальненням даних за допомогою різних моделей обчислювального інтелекту. При розв'язанні задач, що містять велику кількість пропущених даних

(наприклад, задачі побудови моделі якості кондитерських виробів від різних характеристик сировини і параметрів технологічного процесу [293]) ефективно застосовувати метод на основі асоціативних правил ($E = 0,032$), оскільки формування таких правил не передбачає необхідності наявності повної інформації (значень всіх ознак) про кожен з об'єктів навчальної вибірки $S = \langle P, T \rangle$. Важливо відзначити, що для можливості порівняння методу на основі асоціативних правил з іншими методами навчальна вибірка перетворювалася таким чином, що значення пропущених ознак в екземплярів приймалися такими, що дорівнюють середнім значенням відповідних ознак, а екземпляри з великою кількістю пропущених значень (більше половини) цілком виключалися з навчальної вибірки. Це дозволило застосовувати методи на основі дерев розв'язків, негативного відбору і зворотного поширення помилки для оброблення даних, що містять велику кількість пропусків, однак істотно знизило точність таких методів ($E = 0,047$, $E = 0,141$, $E = 0,039$, відповідно). Запропонований паралельний метод видобування правил також забезпечив високу точність при обробленні вибірки, що містить велику кількість пропущених значень ($E = 0,029$ для CPU і $E = 0,031$ для GPU).

Помилка на тестових даних E_t нейро-нечіткої моделі, синтезованої за допомогою методу зворотного поширення помилки, при розв'язанні практичних задач суттєво зростає (наприклад, для задачі розпізнавання автотранспортних засобів [352] $E = 0,009$ і $E_t = 0,053$, відповідно). Це обумовлено низькими узагальнювальними властивостями та високою складністю (великою кількістю нейроелементів) моделі, синтезованої на основі повної навчальної вибірки $S = \langle P, T \rangle$. Аналогічні результати показали й інші методи. Важливо відзначити, що в ряді випадків результати, отримані за допомогою методів на основі дерев розв'язків, асоціативних правил і негативного відбору, є, як правило, прийнятними. Наприклад, для задачі побудови моделі якості кондитерських виробів від різних характеристик сировини і параметрів технологічного процесу [293] помилка на тестових даних

E_t моделі, синтезованої на основі асоціативних правил, є прийнятною ($E_t = 0,049$, $E = 0,032$). Проте, помилки на тестових даних при розв'язанні зазначеної задачі за допомогою методів на основі дерев розв'язків і негативного відбору перевищують п'яти процентний поріг ($E_t = 0,082$ і $E_t = 0,192$, відповідно), що є неприйнятним для даної задачі. При вирішенні інших задач більш прийнятні результати показали методи на основі дерев розв'язків і негативного відбору: наприклад, для задачі діагностування якості життя хворих хронічним обструктивним бронхітом від сполучення використовуваних лікарських засобів [292] помилки на тестових даних моделей, синтезованих за допомогою зазначених методів, склали $E_t = 0,037$ та $E_t = 0,041$ у порівнянні з помилкою $E_t = 0,068$ при використанні методу на основі асоціативних правил. Відзначимо, що запропонований паралельний метод забезпечив побудову моделей з високими узагальнювальними властивостями (низькими значеннями помилок E_t , розрахованих при використанні тестових даних) при розв'язанні всіх задач, не залежно від особливостей навчальної вибірки, що обумовлено видобуванням правил на різних вузлах паралельної системи за допомогою різних засобів обчислювального інтелекту (дерев розв'язків, асоціативних правил, негативного відбору).

Таким чином, порівнюючи значення оцінок E_t для різних методів та різних практичних задач, видно, що запропонований паралельний метод дозволив в середньому покращити узагальнювальні властивості синтезованих діагностичних моделей на 43 %.

У деяких випадках показник якості діагностування на тестових даних E_t є надзвичайно важливим, оскільки неправильно розпізнаний виріб може привести до непоправних утрат. До таких задач відноситься задача діагностування лопаток газотурбінних авіадвигунів по спектрах вільних загасаючих коливань [292, 348], оскільки неправильне віднесення великої кількості дефектних лопаток до класу кондиційних може привести до виходу

авіадвигуна з ладу і поломки всього літака. Запропонований паралельний метод дозволив синтезувати нейромоделі з найкращим рівнем узагальнення (помилка розпізнавання на тестових даних склала $E_t = 0,011$).

Аналіз чисельних значень параметрів E і E_t дозволяє зробити висновок про те, що запропонований паралельний метод видобування продукційних правил показав високу ефективність при роботі з різними вибірками даних. Це обумовлено застосуванням у паралельному режимі різних методів і засобів обчислювального інтелекту (дерев розв'язків, асоціативних правил, негативного відбору), які дозволяють ефективно обробляти набори даних, що характеризуються різними властивостями – із пропусками даних, бінарні дані, дійсні дані та ін.

Чисельні результати, наведені в табл. 7.5, підтверджують, що час побудови нейромоделей t за допомогою паралельного підходу суттєво (у середньому в 3–9 разів) менше часу, затрачуваного на аналогічні процеси при використанні послідовних методів. Наприклад, для задачі розпізнавання автотранспортних засобів [352] час побудови моделі при застосуванні запропонованого методу на CPU склав 1234,8 с., що на порядок нижче часу ($t = 27191,2$), затрачуваного при синтезі нейро-нечіткої моделі за допомогою методу зворотного поширення помилки на основі усієї вибірки даних $S = \langle P, T \rangle$. Використання видобутого набору правил для синтезу розпізнавальних моделей також дозволяє скоротити час синтезу, що обумовлено істотним зменшенням обсягу навчальної вибірки, представленої в даному випадку з виділених продукційних правил. Загальний час побудови розпізнавальної моделі за допомогою методів на основі дерев розв'язків, асоціативних правил і негативного відбору склав, відповідно, 8295,1, 7409,8 і 3981,4 с., що в рази вище часу роботи запропонованого паралельного методу.

Таким чином, запропонований паралельний метод дозволяє суттєво (в 3–9 разів) скоротити витрати часу на видобування продукційних правил і синтез на їх основі діагностичних моделей. При цьому забезпечується побудова

моделей з високими апроксимаційними й узагальнювальними властивостями (низькі значення помилок розпізнавання на навчальних і тестових даних, відповідно). Порівнюючи значення оцінок E_t для різних методів та різних практичних задач, визначено, що запропонований паралельний метод дозволив в середньому покращити узагальнювальні властивості синтезованих діагностичних моделей на 43 %. Крім того, запропонований метод видобування продукційних правил забезпечує можливість ефективної роботи на різних вибірках даних (з різними властивостями – із пропусками даних, бінарними даними, дійсними даними та ін.). Це обумовлено паралельною обробкою даних за допомогою різних методів і засобів обчислювального інтелекту (дерев розв’язків, асоціативних правил, негативного відбору).

Також було виконано експериментальне дослідження запропонованої у п. 3.3 нейромережевої моделі оцінювання використовуваних ресурсів комп’ютерної системи при виконанні паралельного методу видобування продукційних правил. При проведенні експериментів кількість процесів x_2 , на яких виконувався метод, варіювалася від 1 до 32 для кластерів і від 60 до 260 для GPU. Пропускна здатність мережі x_3 – від 1 до 20 Гб/с, частки α_{DT} , α_{AR} , α_{NS} від 0 до 1 (при цьому $\alpha_{DT} + \alpha_{AR} + \alpha_{NS} = 1$). Для проведення експериментів було розроблено програмне забезпечення з застосуванням бібліотек MPI [151] і CUDA [152].

Результати експериментів на кластері при $M=10240$; $Q=318$; $\alpha_{DT} = 0,2$; $\alpha_{AR} = 0,3$; $\alpha_{NS} = 0,5$ наведено на рис. А.8. Суцільною лінією зображено фактично витрачені системою час (с) і пам’ять (Мб) на виконання паралельного методу видобування продукційних правил [286], а пунктирною лінією – розрахункові за допомогою запропонованої моделі час і пам’ять. Результати експериментів на кластері при $M=1023$; $Q=95$; $\alpha_{DT} = 0,2$; $\alpha_{AR} = 0,3$; $\alpha_{NS} = 0,5$ наведено на рис. А.9. Результати експериментів на графічному процесорі при $M=10240$; $Q=318$; $\alpha_{DT} = 0,15$; $\alpha_{AR} = 0,28$; $\alpha_{NS} = 0,57$ наведено на рис. А.10.

Тестова вибірка, що складається з результатів 149 експериментів, містила результати розв'язання практичних задач у паралельній системі, що не входять у навчальну вибірку.

З рис. А.8–А.10 видно, що час розв'язання задачі й обсяг використаної пам'яті, розраховані за допомогою запропонованої моделі, як правило, є трохи меншими в порівнянні з фактично витраченим часом і обсягом пам'яті. Це можна пояснити тим, що час і пам'ять, витрачені при синхронізаціях і пересиланнях даних між процесами кластера і потоками графічного процесора, значно варіюються. При цьому, чим більше задіяно процесів (потоків), тим суттєвішим є вплив синхронізацій і пересилань і тим більшим є відхилення між фактичним і прогнозованим часом та обсягом пам'яті.

Середньоквадратична помилка $MSE=2,31 \times 10^{-3}$, розрахована для обсягу витраченої пам'яті Mem , є значно нижчою, ніж $MSE=9,64 \times 10^{-2}$, розрахована для часу обчислень T . Це пов'язано з тим, що на процес використання пам'яті при виконанні розглянутого методу впливає значно менше факторів і він краще прогнозується, ніж процес виконання обчислень у цьому ж методі. У цілому обидві величини MSE знаходяться в прийнятному діапазоні, що дозволяє рекомендувати використання запропонованої моделі на практиці.

Таким чином, результати експериментів показали, що розроблені методи видобування продукційних правил показали свою ефективність при використанні на різних вибірках даних. Високу ефективність при обробці великих вибірок з дубляжем інформації, що містять велику кількість ознак і екземплярів, у т.ч. надлишкових, показав метод видобування правил на основі дерев розв'язків. При обробці наборів даних з великою кількістю пропущених значень або вибірок, поданих у вигляді баз транзакцій, доцільним є використання методу на основі асоціативних правил. У випадках нерівномірного розподілу екземплярів по класах вибірки для видобування продукційних правил ефективно може застосовуватися метод на основі негативного відбору, що дозволяє виявляти аномалії або випадкові зміни в

діагностованих об'єктах. Запропонований паралельний метод видобування продукційних правил забезпечує можливість ефективної роботи на різних вибірках даних (з різними властивостями – із пропусками даних, бінарними даними, дійсними даними та ін.), що обумовлено паралельною обробкою даних за допомогою різних методів і засобів обчислювального інтелекту (дерев розв'язків, асоціативних правил, негативного відбору).

7.3 Експериментальне дослідження методів редукції даних

Для експериментального дослідження ефективності використання запропонованого паралельного методу редукції великих даних (ПМРВД) було проведено чисельні експерименти, які ґрунтувалися на розв'язанні задачі відбору інформативних ознак для розпізнавання автотранспортних засобів [294, 352]. Як відзначено вище, навчальна вибірка містила інформацію про зображення транспортних засобів, отриманих з автомобільних доріг, знятих у тонах сірого і відображених на матрицю розміром 128×128 (16384 точок). Отримані зображення перетворювалися шляхом обчислення 26 характеристик, що узагальнюють графічну інформацію про об'єкт [294, 352] (табл. А.5). Для кожного класу автотранспортного засобу синтезувалася своя розпізнавальна модель, що дозволяє визначати, чи відноситься розпізнаваний засіб до даного типу (мотоцикл, легковий автомобіль, вантажне авто, автобус, мінівен чи мікроавтобус). Таким чином, отримано п'ять навчальних вибірок $S = \langle P, T \rangle$ про екземпляри, кожний з яких характеризувався 26 ознаками. Задача полягала в скороченні кількості ознак навчальних вибірок для виділення найбільш інформативних комбінацій, що складаються не більш, ніж з 12 ознак.

Дослідження запропонованого паралельного методу редукції великих даних на основі паралельних обчислень проводилося у порівнянні з такими

методами відбору ознак: метод аналізу головних компонент (МАГК) [59, 129], метод групового врахування аргументів (МГВА) [98, 131], канонічний метод еволюційного пошуку (КМЕП) [204–207, 294], метод почергового додавання і видалення ознак (МПДВО) [131, 132, 195], мультиагентний метод відбору інформативних ознак з прямим і непрямим зв'язком між агентами (ММПЗА, ММНЗА) [294]. Як критерій оцінювання інформативності наборів ознак використовувалася помилка розпізнавання за моделлю, синтезованою на основі відповідного набору ознак. Для розпізнавання була застосована нейронна мережа прямого поширення з трьома нейронами на першому шарі й одним нейроном на другому, логістичною сигмоїдною функцією активації нейроелементів і зваженими сумами в якості дискримінантних функцій.

Одним з критеріїв оцінювання для дослідження отриманих результатів розв'язання проблеми відбору ознак було використано кількість ознак k , які сформували інформативний набір ознак. При чому з огляду на те, що рішення проблеми формувалося відразу для п'яти варіантів постановки задачі, то в якості кількості відібраних ознак використовувалося округлене середнє значення, а також окремо інтервал, в який дані значення потрапляли: мінімальне і максимальне значення, тобто найменша і найбільша потужності множини інформативних ознак, відібраних в результаті застосування відповідного методу.

Також будемо оцінювати глибину покриття простору пошуку XS в процесі редукції даних шляхом відбору інформативних ознак. Для цього використаємо критерій $v_{Deep}(iter, XS) = N(iter)/N(XS)$, де $N(iter)$ – кількість унікальних пробних точок $Xe \in XS$, оцінених в процесі відбору ознак до поточної ітерації $iter$, включно, $N(XS)$ – кількість точок дискретного простору XS . Оскільки множина XS являє собою сукупність всіх можливих комбінацій ознак p_m ($m = 1, 2, \dots, M$), одержуваних з вхідної множини ознак P ($|P| = M$),

то величина $N(iter)$ може бути визначена наступним чином:

$$N(XS) = |XS| = 2^M - 1.$$

Альтернативою даному критерію може бути кількість унікальних пробних точок, оцінених на поточній ітерації. Це дозволяє наочно демонструвати збіжність методу в абсолютному вираженні і зокрема порівнювати його з методами, для яких характерне знаходження локальних оптимумів замість глобальних.

Отримані результати етапу відбору ознак безпосередньо впливають на якість отриманих рішень в результаті розпізнавання образів, тому в якості критеріїв дослідження отриманих результатів розв'язання проблеми розпізнавання образів були використані наступні: помилка розпізнавання $E = Q_{ic} / Q$, де Q_{ic} – кількість невірно розпізнаних екземплярів, Q – загальна кількість екземплярів у вибірці; час роботи методу t (с), який знадобився для досягнення прийняттого рішення.

У процесі проведеного дослідження розробленого паралельного методу редукції великих даних на різних вузлах паралельної системи використовувалися еволюційний пошук з групуванням ознак, мультиагентні методи з прямим і непрямим зв'язком між агентами, а також метод еволюційного пошуку з кластеризацією ознак як найбільш релевантні для розв'язання даної задачі, виділені на основі попереднього підготовчого порівняння.

У таблиці А.8 наведено результати формування множини інформативних ознак на основі застосування методів відбору ознак, виражені у вигляді інтервалу і середнього значення потужності такої множини (для варіантів прогнозованого класу розпізнавання). У таблиці А.8 стовбець k позначає середню кількість інформативних ознак у наборах, що були виділені в процесі редукції даних для синтезу п'яти розпізнавальних моделей (для розпізнавання п'яти класів: мотоцикл, легковий автомобіль, вантажне авто, автобус, мінівен чи мікроавтобус), відповідно k_{min} та k_{max} позначають

мінімальну та максимальну кількість у виділених наборах інформативних ознак.

Результати експериментів, продемонстровані в таблиці А.8, показали, що набір, який складається з найменшої кількості інформативних ознак, дозволили виділити мультиагентний метод з непрямым зв'язком між агентами і паралельний метод редукції великих даних (10,2 в середньому). Майже тим же самим набором характеризувався і мультиагентний метод з прямим зв'язком між агентами, і канонічний метод еволюційного пошуку (10,4).

На рис. А.11–А.13 відображено залежність глибини покриття простору пошуку від номера поточної ітерації для трьох методів з найкращими результатами розпізнавання (табл. А.8, рис. А.14–А.15). На рис. А.11 наведено залежність глибини покриття простору пошуку (кількості унікальних пробних точок) від номеру поточної ітерації для канонічного методу еволюційного пошуку.

Як видно з рис. А.11, в процесі роботи методу еволюційного пошуку досить високе початкове покриття простору пошуку швидко знижується (з 0,35 до 0,15, тобто в 2,33 рази за 40 ітерацій), що призводить до того, що значне охоплення простору пошуку реалізується тільки на початковому етапі, відповідно майже половина ітерацій виконується над набором унікальних точок, які складають близько 15% простору пошуку. При цьому при повторенні набору ітерацій (перезапуску еволюційного пошуку з сотої ітерації) початкове охоплення простору пошуку істотно не знижується, тобто повторна реалізація ітерацій починається практично з ідентичного набору унікальних точок (33-35%).

Графік залежності глибини покриття простору пошуку, дослідженого на поточній ітерації, для мультиагентного методу з прямим зв'язком між агентами наведено на рис. А.12.

Як видно з рис. А.12, різкого зниження кількості унікальних точок як в еволюційному пошуку не відбувається (до рівня 15% простір пошуку

знижується за 75 ітерацій, або за 3/4 ітерацій від загальної кількості 100 ітерацій до перезапуску пошуку). Однак даний метод призводить до того, що при перезапуску початкове охоплення простору пошуку постійно знижується: більше 30% унікальних точок розглядається тільки в перші 27 ітерацій, що призводить до того, що на останній стадії реалізації даного методу розглядається невеликий набір точок в порівнянні з початковим.

На рис. А.13 наведено отриману залежність зміни глибини покриття простору пошуку (кількості унікальних пробних точок) у процесі роботи паралельного методу редукції великих даних.

Паралельний метод редукції великих даних (рис. А.13) дозволив фактично успадкувати позитивні риси вивчення простору пошуку від розглянутих вище методів, при цьому розширюючи їх за рахунок введення додаткових контрольних точок. Для оцінювання глибини покриття простору пошуку використано додатково введений показник – відносний час. Це обумовлено тим, що реалізація ітерацій різних стратегій на різних вузлах паралельної системи займає різний час й призводить до того, що для ілюстрації загального охоплення простору пошуку всіма кластерами необхідно нормалізувати дану величину. Відносний час виражається у відсотках від загального часу роботи всієї паралельної системи.

Як видно з рис. А.13, при повторенні набору ітерацій початковий простір пошуку співмірний за кожного такого повторення (34,5-37,2%). Якщо розглядати реалізацію окремо кожного такого повторення, то помітно, що глибина покриття не знижується так швидко як в еволюційному пошуку, що в результаті знижує ймовірність потрапляння в локальні оптимуми. Кожне повторення набору ітерацій закінчується зниженням глибини пошуку до 0, що обумовлено тим, що в цей період часу реалізуються обчислення на головному ядрі Pr_0 , таким чином безпосередньо пошук інформативної комбінації ознак не реалізується.

На рис. А.14 наведено діаграму, яка демонструє розподіл рівня помилки розпізнавання автотранспортних засобів при дослідженні проблеми розпізнавання образів у залежності від використаного методу відбору ознак на відповідному етапі. Співвідношення часу виконання процесу відбору ознак для розпізнавання автотранспортних засобів при застосуванні різних методів відбору ознак наведено на рис. А.15.

Наведені на рис. А.14 та А.15 результати розв'язання задачі розпізнавання автотранспортних засобів (помилка розпізнавання і час виконання) продемонстрували, що найкращі отримані значення відповідають запропонованому паралельному методу редукції великих даних.

Використання запропонованого методу дозволило отримати помилку розпізнавання на рівні 0,0178, що на 8,2% та на 12,3% точніше ніж мультиагентний метод відбору інформативних ознак з непрямым і прямим зв'язком між агентами, відповідно, а також на 19,8% точніше у порівнянні з канонічним методом еволюційного пошуку. Таким чином, кращі результати розпізнавання за точністю продемонстрували методи, які для даного завдання формували множину інформативних ознак з найменшою потужністю.

Одночасно запропонований метод виявився найкращим і за показником часу виконання, значення якого склало 612 с, що обумовлено використанням паралельної комп'ютерної системи. Співмірну швидкість роботи з ним продемонстрував метод аналізу головних компонент, проте його помилка розпізнавання виявилася майже в 2,5 рази гіршою у порівнянні з використанням запропонованого методу. Наступним за даним показником виявився метод почергового додавання і видалення ознак, який дозволив виконати розпізнавання за час у 3,7 раз більше ніж запропонований, але характеризувався найбільшою серед розглянутих методів помилкою розпізнавання (0,0484). Мультиагентні методи з непрямым і прямим зв'язком між агентами, які характеризувалися співмірною з запропонованим методом

помилкою розпізнавання, виконали розпізнавання в 17,24 і 16,89 разів повільніше за нього.

Узагальнені результати порівняння методів відбору інформативних ознак для розв'язання завдання розпізнавання автотранспортних засобів наведено у таблиці 7.6.

Таблиця 7.6 – Результати дослідження методів відбору інформативних ознак при розпізнаванні автотранспортних засобів

Метод відбору ознак	Значення критеріїв порівняння		
	<i>E</i>	<i>t</i>	<i>k</i>
Метод аналізу головних компонентів [59, 129]	0,0441	618	12,4
Метод групового урахування аргументів [98, 131]	0,0363	18306	11,2
Канонічний метод еволюційного пошуку [204–207, 294]	0,0222	23415	10,4
Метод почергового додавання і видалення ознак [131, 132, 195]	0,0484	2262	12,2
Мультиагентний метод з непрямим зв'язком між агентами [294]	0,0203	10549	10,2
Мультиагентний метод з прямим зв'язком між агентами [294]	0,0194	10337	10,4
Паралельний метод редукції великих даних [315]	0,0178	612	10,2

Таким чином, результати експериментів показали, що запропонований паралельний метод редукції великих даних у порівнянні з іншими методами дозволяє розширити покриття простору пошуку, що обумовлено використанням різних стратегій стохастичного пошуку, що ґрунтуються на еволюційному і мультиагентному підходах та реалізуються на різних вузлах

паралельної системи. Розроблений метод дозволяє підвищити різноманітність множини рішень поточної популяції за рахунок введення додаткових контрольних точок до поточної множини рішень. У порівнянні з іншими методами відбору інформативних ознак запропонований метод шляхом застосування паралельних обчислень дозволяє суттєво (у рази) скоротити час пошуку інформативної комбінації ознак.

Для дослідження ефективності застосування на практиці запропонованої у розділі 4 системи оцінювання інформативності ознак для синтезу діагностичних моделей було проведено чисельні експерименти, які ґрунтувалися на розв'язанні задачі відбору інформативних ознак для розпізнавання автотранспортних засобів [294, 352]. Для оцінювання групової інформативності підмножин ознак навчальної вибірки було використано запропоновану систему критеріїв оцінювання інформативності. При обчисленні групової інформативності $V(P^*)$ використовувалася відстань Хеммінгу. Після цього необхідно було виділити підмножину ознак навчальних вибірок. Для пошуку найбільш інформативної комбінації ознак використовувалися методи відбору ознак, наведені вище. Після виділення інформативної комбінації ознак виконувалася побудова розпізнавальної моделі у вигляді нейронної мережі прямого поширення з трьома нейронами на першому шарі й одним нейроном на другому, логістичною сигмоїдною функцією активації нейроелементів і зваженими сумами в якості дискримінантних функцій. Для синтезованих нейромоделей розраховувалася помилка розпізнавання.

У таблиці 7.7 наведено числові характеристики роботи різних методів відбору інформативних ознак при використанні запропонованого критерію $V(P^*)$ оцінювання групової інформативності підмножин ознак.

Таблиця 7.7 – Порівняльний аналіз методів редукції даних при використанні різних критеріїв оцінювання інформативності ознак

Метод відбору ознак	Значення критеріїв порівняння			
	E	$V(P^*)$	t	k
Метод аналізу головних компонентів [59, 129]	0,0412	0,197	62,9	12,4
Метод групового урахування аргументів [98, 131]	0,0358	0,224	1371	11,6
Канонічний метод еволюційного пошуку [204–207, 294]	0,0272	0,412	1749	10,8
Метод почергового додавання і видалення ознак [131, 132, 195]	0,0507	0,172	208,3	12,6
Мультиагентний метод з непрямим зв'язком між агентами [294]	0,0304	0,457	925,2	10,8
Мультиагентний метод з прямим зв'язком між агентами [294]	0,0312	0,481	907,8	10,4
Паралельний метод редукції великих даних [315]	0,0242	0,552	58,1	10,4

Як видно з табл. 7.7, час пошуку t інформативної комбінації ознак при використанні запропонованого критерію оцінювання групової інформативності $V(P^*)$ є суттєво (в рази) нижчим у порівнянні з часом редукції даних при використанні аналогічних методів (табл. 7.6), де як цільовий критерій використовується функція помилки моделі, побудованої за оцінюваним набором ознак.

Це обумовлено тим, що при використанні запропонованого критерію оцінювання групової інформативності ознак $V(P^*)$ не потрібно реалізовувати в процесі редукції даних процедуру синтезу моделей за вибіркою даних для кожного оцінюваного набору ознак, яка є досить обчислювально складною і довгою. Це дозволяє використовувати запроповану систему критеріїв

оцінювання інформативності в тому числі в умовах обмеженості часу і ресурсів, та, відповідно, збільшити практичний поріг обмеження розмірності даних при синтезі діагностичних моделей.

При цьому значення помилки E моделі, побудованої за виділеним набором ознак (табл. 7.7), не суттєво відрізняються від аналогічних значень при використанні помилки E в якості цільового критерію при відборі ознак (табл. 7.6).

Таким чином, результати експериментів показали, що запропонований паралельний метод редукції великих даних дозволяє розширити покриття простору пошуку та підвищити різноманітність множини рішень поточної популяції за рахунок введення додаткових контрольних точок до поточної множини рішень. У порівнянні з іншими методами відбору інформативних ознак запропонований метод шляхом застосування паралельних обчислень дозволяє суттєво (у разі) скоротити час пошуку інформативної комбінації ознак. Використання запропонованої системи критеріїв оцінювання інформативності ознак дозволяє суттєво знизити час редукції даних, що обумовлено відсутністю необхідності реалізації в процесі редукції даних процедури синтезу моделей за вибіркою даних для кожного оцінюваного набору ознак. Отже, запропоновані паралельний метод редукції великих даних та система оцінювання інформативності ознак можуть ефективно використовуватися для скорочення розмірності даних в процесі синтезу діагностичних моделей.

7.4 Експериментальне дослідження методів синтезу нейро-нечітких діагностичних моделей

З метою дослідження ефективності запропонованого методу синтезу нейро-нечітких моделей на основі паралельного випадкового пошуку

проведено експерименти на комп'ютерному кластері та векторному процесорі. Для проведення експериментального дослідження на кластері виконувалося розв'язання задачі діагностування лопаток газотурбінних авіадвигунів [348]. Навчальна вибірка $S = \langle P, T \rangle$ (табл. А.6) містила інформацію про спостереження (лопатки), кожне з яких являло собою набір значень спектрів потужності вільних загасаючих коливань після удару. Вихідний параметр T кожної лопатки P_q містив інформацію про кондицію лопатки (нульове значення відповідало дефектним лопаткам, одиничне – придатним). Стан кожної лопатки P_q визначався за допомогою нанесення ударного збудження і знімався з її сигналів, що піддавалися спектральному аналізу, у результаті чого сформувалося 2610 характеристик сигналів, кожна з яких являла собою значення m -го атрибута p_{qm} q -ї лопатки.

Задача полягала в побудові діагностичної моделі, що дозволяє виконувати розпізнавання дефектних лопаток авіадвигунів за значеннями спектрів потужності вільних загасаючих коливань після ударного порушення. При цьому було потрібно побудувати модель, що забезпечує нульовий рівень помилки, тому дострокових виходів із процесів випадкового пошуку не було, завершення стохастичної оптимізації відбувалося по досягненню гранично припустимої кількості ітерацій (це забезпечило можливість більш детального дослідження різних характеристик запропонованого методу). Розроблений паралельний метод параметричної ідентифікації нейро-нечітких моделей (ПМПНМ) порівнювався з острівною моделлю еволюційного пошуку (Island Genetic Algorithm, IGA [267, 269, 299]), що також використовує паралельні обчислення в процесі еволюційної оптимізації. Експерименти були виконані по декілька разів на одному, двох, чотирьох, шести, восьми, десяти, дванадцяти, чотирнадцяти і шістнадцяти процесорах.

На рис. А.16 зображено залежність помилки розпізнавання E синтезованої нейро-нечіткої моделі NFN від часу виконання паралельних

методів ПМПІНМ та IGA при різній кількості процесів N_{pr} паралельної системи.

Як видно, запропонований метод [325] дозволяє швидше досягти прийнятних результатів. Наприклад, при $N_{pr} = 4$ розроблений метод дозволив за 36,63 с. забезпечити побудову нейро-нечіткої мережі з рівнем помилки $E = 0,0085$; при використанні острівної моделі еволюційного пошуку за 53,16 с. була синтезована нейро-нечітка модель, що характеризується помилкою $E = 0,023$. За результатами експериментів, відображеними на рис. А.16, виявлено, що за однаковий (обмежений) час розроблений метод ПМПІНМ дозволяє синтезувати моделі, які є в середньому точніше на 75,2% у порівнянні з нейро-нечіткими моделями, синтезованими за допомогою методу IGA. У випадку необмеженості часу пошуку усі методи не дозволили побудувати моделі, які б забезпечували нульовий рівень помилки, отже, процес пошуку припинявся при виконанні критерію зупинення, пов'язаного з досягненням максимально припустимої кількості ітерацій. При цьому запропонований метод в середньому працював до зупинення на 31,1% часу менше у порівнянні з методом IGA та дозволяв синтезувати нейро-нечіткі діагностичні моделі, що характеризуються на 64% кращими показниками точності (зокрема, при $N_{pr} = 4$ точність моделі, синтезованої за допомогою запропонованого методу, становить $E = 0,0085$, а за допомогою методу IGA $E = 0,023$, що є на $100\% \cdot (0,023 - 0,0085)/0,023 = 63\%$ краще).

Скорочення часу виконання паралельного випадкового пошуку в запропонованому методі в порівнянні з методом IGA обумовлюється наступними факторами:

- використання апріорної інформації про навчальну вибірку шляхом врахування значущості термів ознак виходячи з щільності розташування екземплярів навчальної множини у відповідних термах і ступеню їхнього впливу на значення вихідного параметра. З рисунку видно, що на початкових

ітераціях пошуку кожний з порівнюваних методів (ПМПННМ і IGA) не залежно від кількості процесів N_{pr} паралельної системи забезпечував побудову нейро-нечітких моделей, що характеризуються приблизно однаковими значеннями помилки розпізнавання E . При цьому помилка E нейро-нечітких моделей, синтезованих за допомогою запропонованого методу, на початкових ітераціях була істотно нижчою, ніж помилка моделей, побудованих за допомогою методу IGA. Це пов'язано з тим, що на етапі ініціалізації в запропонованому методі використовується апріорна інформація про навчальну вибірку, що дозволяє наблизити початкові точки пошуку до областей розташування екстремумів і прискорити процес оптимізації. При використанні острівної моделі еволюційного пошуку IGA початкова популяція формується випадковим чином, що відображається на значеннях помилки розпізнавання нейро-нечітких мереж, і, отже, вимагає великих обчислювальних витрат при пошуку значень параметрів синтезованих моделей;

– наявність механізмів підтримки розмаїтості в популяції, що дозволило забезпечити пошук у різних екстремальних областях і більш детально досліджувати простір пошуку, внаслідок чого за менший час досягти більш прийнятної в порівнянні з методом IGA значення помилки синтезованої нейро-нечіткої моделі;

– застосування модифікованих операторів створення нових рішень шляхом схрещування та мутації, у яких враховуються особливості розташування параметрів, що налаштовуються, їхній тип (параметри функцій належності нейронів, вагові коефіцієнти нейроелементів), пристосованість рішень-батьків, а також допускається вихід за межі відповідних діапазонів, що дозволяє розширювати область пошуку і не витрачати часові й обчислювальні ресурси у випадку зациклення в областях локальних екстремумів.

На рис. А.17 наведено усереднені часові витрати на побудову нейро-нечітких моделей за допомогою різних паралельних методів. З рис. А.17 видно, що метод ПМПННМ у порівнянні з методом IGA дозволяє швидше

виконувати паралельний випадковий пошук, оскільки застосування модифікованих операторів створення нових рішень зменшує загальну кількість виконуваних на процесах операцій.

Зазначимо, що при використанні послідовного підходу ($N_{pr} = 1$) процес синтезу діагностичних нейро-нечітких моделей є в рази довшим у порівнянні з використанням паралельного підходу ($N_{pr} \geq 2$).

На рис. А.18 та А.19 наведено графіки прискорення й ефективності, відповідно, паралельної системи при виконанні запропонованого методу і методу IGA. Як видно з графіків, наведених на рис. А.18 та А.19, прискорення запропонованого методу майже лінійно зростає пропорційно кількості процесів. При цьому повільне зниження ефективності системи зі зростанням кількості процесів свідчить про гарну масштабованість запропонованого методу на паралельній архітектурі MPP (масивна-паралельна система) [150]. У порівнянні з методом IGA запропонований метод продемонстрував кращу масштабованість. Це обумовлено такими причинами:

- затрачається менше часу на синхронізацію процесів;
- підготовка даних до пересилання відбувається швидше.

Головною причиною зниження прискорення є пересилання. Для оцінки частки пересилань між процесами були реалізовані виклики функцій `MPI_Wtime` безпосередньо перед і після кожного пересилання. У ході аналізу запропонованого методу встановлено, що частота міграцій впливає на кількість пересилань: чим частіше виконуються міграції, тим більше необхідно пересилань між процесами. Відсоток мігруючих особин так само впливає на обсяг даних при пересиланнях.

Для оцінки впливу пересилань на обчислювальний процес були виконані експерименти, у яких варіювалися частота міграцій і відсоток мігруючих особин, та оцінювався час пересилань у залежності від кількості процесів.

Результати оцінювання частки пересилань при різних частотах міграції L_{migr} і відсотках мігруючих особин L_{Hmigr} наведено у табл. А.9. З табл. А.9

помітно, що зростання частоти міграцій збільшує час і частку пересилань по відношенню до цільових обчислень на кластері істотніше, ніж зростання відсотку мігруючих особин. Це пов'язано з тим, що часові витрати на ініціалізацію пересилань у паралельному середовищі виконуються довше, ніж самі пересилання.

На рис. А.20 наведено графік залежності частки пересилань від кількості процесів при різних частотах міграції L_{migr} та частки мігруючих особин $L_{Hmigr} = 2\%$. Частка пересилань зростає швидше зі збільшенням кількості процесів. Коли частка пересилань перевищить частку цільових обчислень, ефективність такої системи стане низькою.

Запропонований метод ПМПІННМ і метод IGA показали однаковий час, затрачений на пересилання даних між процесами, однак, частка таких пересилань від загального часу обчислювального процесу в методі IGA менше.

Як видно з табл. А.9, збільшення частоти міграцій та відсотку мігруючих особин суттєво збільшує частку пересилань і, тим самим знижує ефективність паралельної системи у відношенні часу обчислювального процесу. Тому на практиці доцільно вибирати невисокі значення параметрів частоти міграцій і частки мігруючих особин, що дозволить при збереженні прийнятної точності істотно знизити час обчислювального процесу на кластері.

Перевага векторного процесору над центральним процесором полягає в тому, що велику частину кристалу центрального процесору займає керуючий пристрій, у той час як кристал векторного процесору практично цілком заповнений безпосередніми виконавцями обчислень. З рис. А.16–А.20 видно, що запропонований метод добре розпаралелюється на SIMD-архітектурі, коли один потік інструкцій виконується на кожному процесі над вектором даних. Тому доцільно виконати експерименти на векторному процесорі та порівняти ефективність його застосування з ефективністю застосування кластера для реалізації запропонованого методу.

Для проведення експериментів в якості представника SIMD-архітектури будемо використовувати графічний процесор (GPU) NVIDIA GTX285, що програмується за технологією Nvidia CUDA [152] та містить 240 потокових процесорів, кожний з яких може виконувати окремий обчислювальний потік.

На рис. А.21 наведено усереднені часові витрати на побудову нейро-нечітких моделей за допомогою запропонованого методу ПМПІННМ і острівної моделі еволюційного пошуку IGA і на векторному процесорі. На рис. А.22 зображено графік прискорення обчислювального процесу на GPU. В якості часу виконання методу на одному процесі взято час виконання на одному процесі кластера. Це зроблено для забезпечення можливості порівняння прискорення на кластері і на GPU. З рис. А.22 видно, що зі зростанням кількості потоків понад 160 прискорення починає зростати істотно повільніше, ніж до цього моменту. Це пов'язано з тим, що кількість потоків, які реалізують ітерації алгоритму насичують приблизно 120 потоків GPU, інші потоки векторного процесору залишаються незадіяними.

В експериментах на GPU також було оцінено частку пересилань (табл. А.10) у залежності від частоти міграцій L_{migr} та відсотку мігруючих особин L_{Hmigr} . На рис. А.23 наведено графік залежності частки пересилань від кількості потоків. Час пересилань на GPU є більшим, ніж на цілому кластері, оскільки програмний код, який містить пересилання, на GPU виконується послідовно, а не паралельно, що істотніше знижує продуктивність системи в порівнянні з кластером.

Таким чином, проведені на кластері та на векторному процесорі експерименти свідчать про прийнятні значення показників ефективності запропонованого паралельного методу параметричного синтезу нейро-нечітких моделей. Результати експериментів по дослідженню залежності показників ефективності та частки пересилань від кількості процесів показали, що на практиці розроблений метод доцільно застосовувати в кластерах і на векторних

процесорах при задіяній кількості потоків до 120, що дозволяє одержати результати за прийнятний час.

Запропонований метод синтезу нейро-нечітких моделей на основі паралельного випадкового пошуку дозволяє швидше досягти прийнятних результатів у порівнянні з методом IGA, що також використовує паралельний підхід. За результатами експериментів виявлено, що за однаковий (обмежений) час розроблений метод ПМПНМ дозволяє синтезувати моделі, які є в середньому точніше на 75,2% у порівнянні з нейро-нечіткими моделями, синтезованими за допомогою методу IGA. У випадку необмеженості часу запропонований метод в середньому працював до зупинення на 31,1% часу менше у порівнянні з методом IGA та дозволяв синтезувати нейро-нечіткі діагностичні моделі, що характеризуються на 64% кращими показниками точності (зокрема, при $N_{pr} = 4$ точність моделі, синтезованої за допомогою запропонованого методу, становить $E = 0,0085$, а за допомогою методу IGA $E = 0,023$, що є на $100\% \cdot (0,023 - 0,0085) / 0,023 = 63\%$ краще). Визначено, що при використанні послідовного підходу процес синтезу діагностичних нейро-нечітких моделей є в рази довшим у порівнянні з використанням паралельного підходу ($N_{pr} \geq 2$).

Скорочення часу виконання паралельного випадкового пошуку в запропонованому методі в порівнянні з методом IGA обумовлюється використанням апріорної інформації про навчальну вибірку шляхом врахування значущості термів ознак, застосуванням модифікованих операторів створення нових рішень шляхом схрещування та мутації, а також наявністю механізмів підтримки розмаїтості в популяції, що дозволило забезпечити пошук у різних екстремальних областях і більш детально досліджувати простір пошуку, внаслідок чого за менший час досягти більш прийнятної в порівнянні з методом IGA значення помилки синтезованої нейро-нечіткої моделі.

7.5 Експериментальне дослідження методу донавчання діагностичних нейро-нечітких моделей

Для перевірки ефективності розробленого методу донавчання нейро-нечітких моделей вирішувалося завдання побудови діагностичних моделей для прогнозування стану здоров'я хворих на артеріальну гіпертензію [336].

Артеріальна гіпертензія є широко поширеним захворюванням, яке може загрожувати життю та здоров'ю пацієнта [336]. На характер перебігу артеріальної гіпертензії впливають різні фактори (погодні і кліматичні умови, супутні захворювання, а також стан здоров'я в попередні моменти часу) [336]. Для запобігання істотних стрибків тиску пацієнта, які можуть викликати погіршення стану пацієнта, а можливо і привести до летального наслідку, необхідно своєчасно прогнозувати розвиток гіпертензії в короткостроковому періоді часу (на найближчі половину доби або добу). Це дозволить своєчасно реалізувати профілактичні заходи, пов'язані з прийомом необхідних препаратів для запобігання очікуваних негативних наслідків. Для прогнозування стану здоров'я людей, хворих на гіпертонічну хворобу, потрібно мати модель, яка буде унікальною для кожного конкретного пацієнта. Побудова такої моделі потребує обробки великого масиву спостережень, розподілених у часі.

Таким чином, оскільки така хвороба носить індивідуальний характер [336] (особливості перебігу хвороби відрізняються для кожного пацієнта внаслідок чого для кожного пацієнта необхідно синтезувати власну унікальну діагностичну модель) та у зв'язку з отриманням нової інформації про перебіг хвороби з часом, виникає необхідність періодичної перебудови (донавчання) вже існуючих моделей для індивідуального прогнозування стану пацієнтів на основі постійно зростаючих масивів спостережень.

Вихідна вибірка даних $S = \langle P, T \rangle$ про стан здоров'я хворого гіпертонічною хворобою була отримана в м. Запоріжжя. Вибірка містила

результати спостережень декількох років, де кожен екземпляр являв собою набір даних, що характеризують стан пацієнта в певну частину доби [336]. В якості об'єктивних клініко-лабораторних показників використовувалися: p_1 , p_2 – спостережуваний артеріальний тиск (систоличний та діастолічний, мм. рт. ст.); p_3 – пульс (ударів на хвилину); відомості про прийом ліків (p_4 – Амло (0 – ні, 1 – так), p_5 – Егілок (0 – ні, 1 – так); p_6 – Берліприл (0 – ні, 1 – так)). В якості суб'єктивних показників використовувались характеристики самопочуття (p_7 – наявність болю в голові (0 – немає, 1 – є), p_8 – наявність болю в потилиці (0 – немає, 1 – є), p_9 – наявність пульсації (0 – немає, 1 – є), p_{10} – наявність болю в лівому боці (0 – немає, 1 – є), p_{11} – наявність болю в області серця (0 – немає, 1 – є), p_{12} – відчуття нестачі повітря (0 – немає, 1 – є), p_{13} – наявність болю в животі (0 – немає, 1 – є), p_{14} – загальна слабкість (0 – немає, 1 – є)). В якості метеорологічних характеристик [336] використовувалися (p_{15} – температура повітря ($^{\circ}\text{C}$), p_{16} – атмосферний тиск (мм. рт. ст.), p_{17} – тип хмарності (0 – немає, 1 – мала, 2 – хмарно, 3 – похмуро), p_{18} – наявність грози (0 – немає, 1 – є), p_{19} – напрямок вітру (0 – штиль, 1 – північний, 2 – північно-східний, 3 – східний, 4 – південно-східний, 5 – південний, 6 – південно-західний, 7 – західний, 8 – північно-західний), p_{20} – швидкість вітру (м/с), p_{21} – дані сонячної активності (Mg II індекс). В якості часових характеристик використовувалися: код дня тижня (p_{22}), час (година) спостереження (p_{23}), код частини дня (0 – ранок, 1 – вечір) (p_{24}).

Отримані спостереження були використані для формування вибірки для вирішення задачі якісного прогнозування стану пацієнта на найближчу другу половину доби за даними попередніх спостережень: в якості вхідних ознак використовувались дані за попередній період спостережень, а в якості виходу – стан пацієнта (0 – нормальний, 1 – погіршення стану, що супроводжується

підвищенням артеріального тиску). При цьому отримані набори даних було випадковим чином розбито на навчальну вибірку $S = \langle P, T \rangle$ та тестову S_t .

Для виконання експериментів з дослідження розробленого методу донавчання діагностичних нейро-нечітких моделей навчальну вибірку $S = \langle P, T \rangle$ також було розбито на дві частини, перша з яких S_{tr} використовувалася для навчання (синтезу) моделі $NFN = NFN(struct, param)$, а друга S_{ad} – для донавчання вже синтезованої моделі NFN з метою отримання нової моделі $NFNN = NFNN(structN, paramN)$. Варто відзначити, що при розбитті вибірки $S = \langle P, T \rangle$ (табл. А.7) забезпечувалося виконання таких умов: $S_{tr} \cup S_{ad} = S$ та $S_{tr} \cap S_{ad} = \emptyset$, при чому вибірка S_{ad} характеризувала останній період спостережень за пацієнтом.

Нехай величина ω являє собою відношення потужностей множин S_{ad} та S_{tr} :

$$\omega = \frac{|S_{ad}|}{|S_{tr}|}.$$

Чим більшим є значення величини ω , тим більше нових спостережень з'явилося після попередньої побудови (перебудови) моделі NFN .

В процесі експериментальних досліджень будемо застосовувати різні методи та підходи до донавчання побудованих моделей при різних значеннях величини ω :

– донавчання синтезованої нейро-нечіткої моделі NFN за вибіркою S_{ad} методом зворотного поширення помилки [241, 242] (МЗПISad). При цьому в якості початкових параметрів нової моделі $NFNN$ використовувалися параметри наявної моделі NFN , попередньо синтезованої за допомогою вибірки S_{tr} ;

– повторне навчання нейро-нечіткої моделі по даним об'єднаних множин $S_{tr} \cup S_{ad} = S$ (МЗПС);

– використання розробленого методу донавчання діагностичних нейро-нечітких моделей (МДННМ). При цьому донавчання моделі виконувалося за вибіркою S_{ad} , базова модель NFN синтезувалася на основі вибірки S_{tr} .

В якості критеріїв порівняння методів донавчання нейро-нечітких моделей будемо використовувати:

– час донавчання t_{ad} – величина часу, що був затрачений на побудову моделі $NFNN$ (без врахування часу, що був використаний на синтез базової моделі NFN);

– помилка E_S моделі $NFNN$ на даних вибірки $S = \langle P, T \rangle$;

– помилка E_{Str} моделі $NFNN$ на даних вибірки S_{tr} ;

– помилка E_{Sad} моделі $NFNN$ на даних вибірки S_{ad} ;

– помилка E_t моделі $NFNN$ на тестових даних (даних про спостереження, що не відображені у вибірці $S = \langle P, T \rangle$).

Результати експериментів наведено у табл. 7.8.

Таблиця 7.8 – Результати експериментів по дослідженню методів донавчання нейро-нечітких мереж

$\Omega, \%$	t_{ad}			E_S			E_{Str}			E_{Sad}			E_t		
	МЗПС ad	МЗПС	МДН НМ	МЗПС ad	МЗПС	МДН НМ	МЗПС ad	МЗПС	МДН НМ	МЗПС ad	МЗПС	МДН НМ	МЗПС ad	МЗПС	МДН НМ
1	1,8545	187,73	1,576	0,0948	0,0234	0,0234	0,0957	0,0236	0,0236	0,0000	0,0000	0,0000	0,1772	0,0452	0,0438
10	17,027	187,73	15,324	0,0563	0,0234	0,0247	0,0604	0,0211	0,0242	0,0152	0,0455	0,0303	0,1057	0,0452	0,0438
20	31,216	187,73	26,534	0,0536	0,0234	0,0247	0,061	0,0214	0,0247	0,0165	0,0331	0,0248	0,0632	0,0452	0,0464
50	62,433	187,73	47,449	0,0495	0,0234	0,0288	0,0639	0,0227	0,0289	0,0206	0,0247	0,0288	0,0577	0,0452	0,0521
100	93,65	187,73	58,063	0,0426	0,0234	0,0288	0,0604	0,0220	0,0302	0,0247	0,0247	0,0275	0,0548	0,0452	0,0548

З таблиці 7.8 видно, що час донавчання t_{ad} , що був затрачений на побудову моделі $NFNN$ при використанні методу МЗПС є постійним ($t_{ad} = 187,73$ с.) та не залежить від значення величини ω , оскільки донавчання нейро-нечіткої мережі за допомогою такого підходу виконується шляхом використання всієї вибірки даних $S = \langle P, T \rangle$ та не залежить від її розбиття на вибірку S_{tr} , що використовувалась для навчання базової моделі NFN , та вибірку S_{ad} для донавчання вже синтезованої моделі NFN (побудови нової моделі $NFNN$). Варто відзначити, що при невеликих обсягах даних (низькій кількості екземплярів навчальної вибірки $S = \langle P, T \rangle$) час синтезу моделі $NFNN$ є прийнятним. Проте використання такого підходу МЗПС при обробленні великих масивів даних для перебудови вже синтезованих моделей є небажаним, а в деяких випадках і неможливим, оскільки процес донавчання (повторного навчання) буде вимагати значних часових затрат та апаратних ресурсів комп'ютеру.

Час донавчання t_{ad} при використанні методу МЗПСad залежить від значення величини ω (змінюється від 1,8545 с. при $\omega = 1\%$ до 93,650 с. при $\omega = 100\%$), що обумовлено тим, що в якості вибірки, за якою виконується донавчання ННМ, використано скорочену вибірку S_{ad} . Аналогічні результати показує запропонований метод МДННМ. Проте час донавчання дещо нижчий (змінюється від 1,576 с. при $\omega = 1\%$ до 58,063 с. при $\omega = 100\%$) в порівнянні з часом донавчання за допомогою методу МЗПСad. Це обумовлено тим, що у запропонованому методі виконується попереднє групування нових екземплярів, внаслідок чого суттєво зменшується кількість нових правил, які вводяться у нейро-нечітку діагностичну модель, а це, у свою чергу, забезпечує зменшення кількості параметрів, що налаштовуються, та, відповідно, часу донавчання моделі. Таким чином, запропонований метод МДННМ дозволяє суттєво підвищити швидкість донавчання нейро-нечітких діагностичних моделей (у 119 разів при $\omega = 1\%$ та у 3,23 рази при $\omega = 100\%$) у порівнянні з методом МЗПС.

Помилка E_S на вибірці $S = \langle P, T \rangle$ для методу МЗПС є постійною ($E_S = 0,0234$) та такою, яка не залежить від величини ω , оскільки донавчання (повторний синтез моделі) виконується по всій вибірці даних $S = S_{tr} \cup S_{ad}$. Помилка E_S для методу МЗПСad є дещо гіршою у порівнянні з МЗПС (особливо при низьких значеннях величини ω : $E_S = 0,0948$ при $\omega = 1\%$, $E_S = 0,0426$ при $\omega = 100\%$), оскільки для донавчання використовується скорочена вибірка S_{ad} , яка являє собою лише деяку частину вибірки $S = \langle P, T \rangle$. Як видно з таблиці, помилка E_S для методу МЗПСad зменшується зі збільшенням значення величини ω . Це пояснюється збільшенням частки вибірки S_{ad} по відношенню до $S = \langle P, T \rangle$ при збільшенні ω . Варто відзначити, що при розв'язанні практичних задач кількість нових даних (величина ω), як правило, є суттєво нижчою від обсягу початкової інформації (вибірки $S = \langle P, T \rangle$). Це підтверджує доцільність використання запропонованого методу, в якому помилка E_S на вибірці $S = \langle P, T \rangle$ майже не змінюється (не суттєво залежить) при зміні значень величини ω та є співрозмірною з величиною помилки E_S при використанні підходу МЗПС. Це обумовлено використанням формули (6.22) для обчислення значень вихідного параметру T , яка враховує як попереднє узагальнення даних вибірки S_{tr} у вигляді базової моделі NFN (значення вихідного параметру $t(s)$ обчислюється за базовою моделлю NFN у випадку, якщо екземпляр s характеризується низьким ступенем належності $\bigcup_{j=1}^{N_{RNB}} \mu_{NBj}^{(2)} \leq \mu_{\min}$ до правил нового структурного елемента моделі у вигляді корегуючого блоку), так і дані нової вибірки S_{ad} , узагальнені у вигляді корегуючого блоку NB (значення вихідного параметру $t(s)$ обчислюється за корегуючим блоком NB у випадку, якщо екземпляр s

характеризується високим ступенем належності $\bigcup_{j=1}^{N_{RNB}} \mu_{NBj}^{(2)} > \mu_{\min}$ до правил нового структурного елементу).

Величина помилки E_{Str} на вибірці S_{tr} для методу МЗПС (коливається в межах від 0,0211 до 0,0236) є аналогічною величині помилки E_S . Помилка E_{Str} , розрахована на основі вибірки S_{tr} при використанні моделі, побудованої методом МЗПСad, є доволі високою при малих значеннях величини ω ($E_{Str} = 0,0957$ при $\omega = 1\%$, $E_{Str} = 0,0604$ при $\omega = 10\%$, $E_{Str} = 0,0604$ при $\omega = 100\%$). Це є неприйнятним результатом, який обґрунтовується використанням тільки екземплярів вибірки S_{ad} при побудові нової моделі $NFNN$. Помилка E_{Str} при використанні методу МДННМ є доволі низькою, зокрема і при невеликих значеннях показника ω ($E_{Str} = 0,0236$ при $\omega = 1\%$, $E_{Str} = 0,0242$ при $\omega = 10\%$, $E_{Str} = 0,0302$ при $\omega = 100\%$). Такі значення величин E_{Str} підтверджують, що запропонований метод особливо доцільно використовувати при низьких значеннях ω , тобто у випадках, коли обсяг нової інформації S_{ad} про досліджувані об'єкти або процеси є суттєво нижчим за обсяг наявної інформації S_{tr} , яка використовувалася для побудови базової моделі NFN .

З таблиці видно, що значення помилки E_{Sad} , розрахованої на основі даних вибірки S_{ad} , при малих значеннях ω (1%) є нульовими для усіх методів, що свідчить про їх здатність до введення у вже існуючу модель нових даних. Проте, порівнюючи значення величин E_{Sad} , E_{Str} та E_S , можна зробити висновок, що метод МЗПСad, на відміну від запропонованого методу МДННМ, втрачає свої апроксимаційні здатності при перебудові моделі (значення величини E_S зростає до неприйнятного значення при низьких рівнях величини ω). Метод МЗПС аналогічно запропонованому методу забезпечує синтез (донавчання) нейро-нечітких моделей з прийнятними апроксимаційними

властивостями ($E_s = 0,0234$), проте час донавчання (повторного синтезу) моделі при використанні методу МЗПС є досить високим ($t_{ad} = 187,73$ с.) та співрозмірним з часом навчання базової моделі, що, на відміну від запропонованого методу МДННМ ($t_{ad} = 1,576$ с. при $\omega = 1\%$ та $t_{ad} = 58,063$ с. при $\omega = 100\%$, що значно менше, ніж при використанні методу МЗПС), суттєво обмежує його використання на практиці, особливо при обробці великих даних.

Невисокі значення помилки E_t моделі *NFNN* на тестових даних (за винятком методу МЗПСad при низьких значеннях величини ω), розраховані для тестової вибірки даних (даних про спостереження, що не відображені у вибірці $S = \langle P, T \rangle$) підтверджують здатність донавчених нейро-нечітких діагностичних моделей до узагальнення даних.

Відзначимо, що при невеликих значеннях ω (1–20 %), тобто коли обсяг нових даних (вибірки для донавчання S_{ad}) є нижчим обсягу навчальної вибірки S_{tr} , запропонований метод МДННМ дозволяє підвищити узагальнювальні властивості діагностичної моделі на 26,6–75,3% у порівнянні з використанням методу МЗПСad (значення помилки на тестовій вибірці $E_t = 0,1772$ та $E_t = 0,0438$ при $\omega = 1\%$, відповідно $\Delta E_t = |0,1772 - 0,0438| / 0,1772 = 75,3\%$; при $\omega = 20\%$ $\Delta E_t = |0,0632 - 0,0464| / 0,0632 = 26,6\%$). У порівнянні з методом МЗПС розроблений метод МДННМ дозволив підвищити рівень узагальнення даних за допомогою синтезованої діагностичної моделі на 3,1 % при невеликих значеннях ω (1–10 %). При більш високих значеннях ω помилка E_t моделі *NFNN* на тестових даних, побудованої за допомогою методу МДННМ, була співрозмірною з аналогічним показником методу МЗПСad та дещо нижчою у порівнянні з методом МЗПС. Тобто у випадку суттєвого збільшення діагностичних даних ($\omega > 50\%$) більш доцільним є повторне навчання діагностичної моделі при необхідності досягнення високих узагальнювальних властивостей синтезованих моделей (при цьому час донавчання буде суттєво вищим, ніж при використанні методу МДННМ).

Таким чином, запропонований метод МДННМ доцільно використовувати при низьких значеннях ω , тобто у випадках, коли обсяг нової інформації S_{ad} про досліджувані об'єкти або процеси є суттєво нижчим за обсяг наявної інформації S_{tr} , яка використовувалася для побудови базової моделі NFN . При цьому використання методу МДННМ дозволяє отримувати нейро-нечіткі діагностичні моделі, що характеризуються більш високим рівнем узагальнення даних (на 3,1–75,3% вищим у порівнянні з іншими методами при різних значеннях величини ω).

Враховуючи те, що при розв'язанні практичних задач кількість нових даних (величина ω), як правило, є суттєво нижчою від обсягу початкової інформації, використання запропонованого методу є доцільним, оскільки помилка E_S моделі $NFNN$ на вибірці $S = \langle P, T \rangle$ майже не змінюється при зміні значень величини ω , а час донавчання є значно меншим (в три та більше разів в залежності від значення величини ω), ніж при використанні методу МЗПС.

7.6 Висновки за розділом 7

Виконано експериментальне дослідження розроблених методів аналізу даних та синтезу діагностичних моделей на основі нейро-нечітких мереж.

Результати експериментів показали, що розроблений стохастичний метод синтезу дерев розв'язків дозволяє підвищити швидкість побудови діагностичних моделей на основі дерев розв'язків (до двох разів) у порівнянні з відомими методами, а також збільшити рівні інтерпретовності (на 12,0–29,1 %) та узагальнення даних (на 9,7–69,9 %) синтезованих моделей. Запропонований стохастичний метод синтезу дерев розв'язків не уступає по якості побудови деревоподібних моделей прийняття рішень відомим методам, і забезпечує

можливість побудови дерева розв'язків з невеликою кількістю структурних елементів і прийнятною точністю розпізнавання.

Визначено, що запропонований стохастичний метод видобування чисельних асоціативних правил дозволяє синтезувати діагностичні моделі на основі асоціативних правил з більш високими рівнями узагальнення даних (вище на 8,6–21,0 %) та інтерпретовності (вище на 20,0–25,4%). Виявлено, що розроблений метод видобування чисельних асоціативних правил дозволяє обробляти чисельну інформацію з пропущеними значеннями, не здійснювати істотну кількість проходів по заданій базі транзакцій, виявляти правила з високим рівнем вірогідності та інших критеріїв оцінювання їхньої якості.

Розроблений метод синтезу продукційних правил на основі негативного відбору за рахунок використання апріорної інформації та виключення малозначущих і надлишкових ознак з вибірки дозволяє скорочувати простір пошуку і час виконання методу (на 8,3–55,7 % у порівнянні з відомими аналогами), а також синтезувати діагностичні моделі у вигляді набору детекторів з високими апроксимаційними й узагальнювальними властивостями (на 32,7–72,8 % вищими у порівнянні з відомими методами). Крім того розроблений метод за рахунок підвищення узагальнювальних властивостей синтезованих моделей шляхом скорочення кількості детекторів і умов антецедентів підвищує інтерпретовність моделі (у 2–10 разів), скорочує її розмірність і, отже, обсяг використовуваної пам'яті.

Запропонований паралельний метод видобування продукційних правил дозволяє суттєво (в 3–9 разів) скоротити витрати часу на видобування продукційних правил і синтез на їх основі діагностичних моделей. При цьому забезпечується побудова моделей з високими апроксимаційними й узагальнювальними властивостями (низькі значення помилок розпізнавання на навчальних і тестових даних, відповідно). Порівнюючи значення оцінок E_t для різних методів та різних практичних задач, визначено, що запропонований паралельний метод дозволив в середньому покращити узагальнювальні

властивості синтезованих діагностичних моделей на 43 %. Крім того, запропонований метод видобування продукційних правил забезпечує можливість ефективної роботи на різних вибірках даних (з різними властивостями – із пропусками даних, бінарними даними, дійсними даними та ін.). Це обумовлено паралельною обробкою даних за допомогою різних методів і засобів обчислювального інтелекту (дерев розв'язків, асоціативних правил, негативного відбору).

Розроблений паралельний метод редукції великих даних дозволяє розширити покриття простору пошуку та підвищити різноманітність множини рішень поточної популяції за рахунок введення додаткових контрольних точок до поточної множини рішень. У порівнянні з іншими методами відбору інформативних ознак запропонований метод шляхом застосування паралельних обчислень дозволяє суттєво (у рази) скоротити час пошуку інформативної комбінації ознак. Використання запропонованої системи критеріїв оцінювання інформативності ознак дозволяє суттєво знизити час редукції даних, що обумовлено відсутністю необхідності реалізації в процесі редукції даних процедури синтезу моделей за вибіркою даних для кожного оцінюваного набору ознак.

Запропонований метод синтезу нейро-нечітких моделей на основі паралельного випадкового пошуку дозволяє швидше досягти прийнятних результатів у порівнянні з методом IGA, що також використовує паралельний підхід. За результатами експериментів виявлено, що за однаковий (обмежений) час розроблений метод ПМПННМ дозволяє синтезувати моделі, які є в середньому точніше на 75,2% у порівнянні з нейро-нечіткими моделями, синтезованими за допомогою методу IGA. У випадку необмеженості часу запропонований метод в середньому працював до зупинення на 31,1% часу менше у порівнянні з методом IGA та дозволяв синтезувати нейро-нечіткі діагностичні моделі, що характеризуються на 64% кращими показниками точності. Визначено, що при використанні послідовного підходу процес

синтезу діагностичних нейро-нечітких моделей є в рази довшим у порівнянні з використанням паралельного підходу ($N_{pr} \geq 2$). Скорочення часу виконання паралельного випадкового пошуку в запропонованому методі в порівнянні з методом IGA обумовлюється використанням апріорної інформації про навчальну вибірку шляхом врахування значущості термів ознак, застосуванням модифікованих операторів створення нових рішень шляхом схрещування та мутації, а також наявністю механізмів підтримки розмаїтості в популяції, що дозволило забезпечити пошук у різних екстремальних областях і більш детально досліджувати простір пошуку, внаслідок чого за менший час досягти більш прийнятної в порівнянні з методом IGA значення помилки синтезованої нейро-нечіткої моделі.

Визначено, що запропонований метод донавчання діагностичних нейро-нечітких моделей доцільно використовувати у випадках, коли обсяг нової інформації S_{ad} про досліджувані об'єкти або процеси є суттєво нижчим за обсяг наявної інформації S_{tr} , яка використовувалася для побудови базової моделі NFN . При цьому використання методу МДННМ дозволяє отримувати нейро-нечіткі діагностичні моделі, що характеризуються більш високим рівнем узагальнення даних (на 3,1–75,3% вищим у порівнянні з іншими методами). Враховуючи те, що при розв'язанні практичних задач кількість нових даних про досліджувані об'єкти діагностування, як правило, є суттєво нижчою від обсягу початкової інформації, використання запропонованого методу є доцільним, оскільки помилка E_S моделі $NFNN$ на вибірці $S = \langle P, T \rangle$ є прийнятною, а час донавчання є значно меншим (в три та більше разів), ніж при використанні методу МЗПС.

Таким чином, узагальнюючи отримані результати чисельних експериментів, можна відзначити, що застосування запропонованих у дисертаційній роботі методів синтезу діагностичних моделей дозволило значно підвищити швидкість побудови діагностичних моделей (в два та більше разів) у порівнянні з методами, які передбачають послідовну реалізацію обчислень,

збільшити рівні інтерпретовності та узагальнення даних синтезованих моделей (на 20–40 %). Розроблені методи можуть застосовуватися до широкого кола задач діагностування, де не є відомими експертні знання про об'єкти діагностування (або природа яких є не добре вивченою), є адаптивними відносно експериментальних спостережень та можуть бути використані при синтезі діагностичних моделей на основі великих вибірок даних. Розроблені методи синтезу діагностичних моделей на основі нейро-нечітких мереж можуть знайти широке застосування та практичне використання при створенні інтелектуальних систем діагностування у різних галузях економіки, зокрема у авіадвигунобудуванні, військовій промисловості, приладобудуванні, медицині тощо.

Список використаних джерел у цьому розділі наведено у повному списку використаних джерел під номерами [1, 6, 9, 24, 57–63, 77–80, 90–92, 98, 129, 131–141, 149–155, 177–180, 195, 204–207, 241, 242, 267, 269, 276, 277, 282, 283, 286, 290, 292–294, 299, 310, 325, 332, 335–352].

ВИСНОВКИ

У дисертаційній роботі вирішено актуальну науково-прикладну проблему розроблення та дослідження методів синтезу діагностичних моделей, які поєднують принципи інтелектуальних та паралельних обчислень, що дозволяє підвищити швидкість процесу побудови діагностичних моделей, збільшити їх інтерпретовність та узагальнювальні можливості.

Відповідно до сформульованої мети в дисертаційній роботі розв'язано такі завдання:

1. Проведено аналіз процесу та методів синтезу діагностичних моделей на основі нейро-нечітких мереж. Визначено, що для синтезу нейро-нечітких мереж ефективно можуть застосовуватися еволюційні методи, які є методами стохастичної оптимізації та не висувають вимог до виду цільової функції і дозволяють вирішувати завдання структурного та параметричного синтезу нейро-нечітких моделей. Показано, що суттєвим недоліком еволюційних методів є їх висока ітеративність, і, відповідно, високі вимоги до обчислювальних ресурсів комп'ютера і часу, що витрачається на оптимізаційний процес. Обґрунтовано доцільність прискорення процесу еволюційної оптимізації шляхом розробки нових високопродуктивних еволюційних методів, які дозволять скоротити час синтезу і навчання нейро-нечітких діагностичних моделей за множинами прецедентів великої розмірності і збільшити практичний поріг обмежень розмірності даних при побудові систем діагностування та неруйнівного контролю якості, а також підвищити інтерпретовність та узагальнювальні можливості синтезованих діагностичних моделей.

2. Запропоновано стохастичний метод синтезу моделей на основі дерев розв'язків, який використовує інформацію про інформативність ознак, складність синтезованого дерева, а також точність його розпізнавання. Це

дозволяє на початковому етапі формувати множину деревоподібних структур, які характеризуються простою ієрархією та невисокою помилкою розпізнавання, у процесі пошуку створювати нові множини розв'язків з урахуванням інформації про значущість ознак та інтерпретовність генерованих дерев, що, у свою чергу, забезпечує можливість побудови дерев розв'язків з невеликою кількістю елементів (вузлів і зв'язків між ними) та прийнятною точністю розпізнавання, а також видобувати на його основі найцінніші екземпляри для структурного синтезу діагностичних моделей.

3. Запропоновано стохастичний метод видобування чисельних асоціативних правил, що передбачає попереднє розбиття значень ознак на інтервали (терми), враховує при цьому ширину діапазону значень і частоту попадання ознак у кожний з термів, використовує імовірнісний підхід для перебору різних сполучень антецедентів і консеквентів асоціативних правил, використовує апріорну інформацію про значущість термів і ознак, що дозволяє обробляти чисельну інформацію при видобуванні асоціативних правил, не здійснювати істотну кількість проходів по заданому набору даних, виявляти правила з високим рівнем вірогідності та інших критеріїв оцінювання їхньої якості.

4. Розроблено метод синтезу продукційних правил на основі негативного відбору для випадку нерівномірного розподілу екземплярів класів вибірки, який при генерації набору детекторів використовує відому інформацію про екземпляри всіх класів вибірки, враховує інформацію про індивідуальну значущість ознак, як форму детектора використовує гіперкуб максимально можливого об'єму, що дозволяє виключати малозначущі та надлишкові ознаки з вибірки, скоротивши тим самим простір пошуку і час виконання методу, а також формувати набір детекторів з високими апроксимаційними й узагальнювальними здібностями. Запропонований метод за рахунок підвищення узагальнювальних властивостей синтезованих моделей шляхом скорочення кількості детекторів та умов антецедентів також підвищує

інтерпретовність моделі, скорочує її розмірність (структурну і параметричну складність), обсяг використовуваної пам'яті та підвищує швидкодію моделі при послідовній реалізації обчислень.

5. Запропоновано паралельний метод видобування продукційних правил на основі обчислювального інтелекту, що передбачає паралельну побудову інтелектуальних моделей, які узагальнюють задані вибірки даних у вигляді моделей на основі дерев розв'язків, асоціативних правил, негативного відбору. Запропонований підхід дозволяє суттєво скоротити часові витрати на синтез моделей при розв'язанні складних практичних задач, що характеризуються великими обсягами діагностичних даних, а також задач, де виникає необхідність у модифікації вже існуючих діагностичних і розпізнавальних моделей у зв'язку з отриманням нової інформації в процесі спостережень за станом досліджуваних об'єктів або процесів. При цьому забезпечується можливість синтезу моделей з високими апроксимаційними й узагальнювальними властивості.

6. Запропоновано систему критеріїв оцінювання інформативності ознак, яка передбачає визначення значущості ознак виходячи з просторового розташування екземплярів різних класів (діапазонів зміни значень вихідного параметра). Розроблена система критеріїв дозволяє оцінювати індивідуальну і групову інформативність ознак при розв'язанні задач діагностування в умовах, коли вихідні вибірки даних містять надлишкові і взаємозалежні ознаки, а також екземпляри з пропущеними значеннями. Запропоновані критерії не вимагають побудови моделей на основі оцінюваних комбінацій ознак, що істотно знижує часові й обчислювальні витрати в процесі відбору інформативних ознак. Використання запропонованих критеріїв для оцінювання та відбору інформативних ознак дозволяє при розв'язанні задач діагностування знижувати структурну складність синтезованих діагностичних моделей, підвищувати їх інтерпретовність та узагальнювальні здібності за рахунок виключення малозначущих, взаємозалежних і надлишкових ознак.

7. Розроблено паралельний стохастичний метод редукції даних, який передбачає використання різних стратегій стохастичного пошуку, що ґрунтуються на еволюційному і мультиагентному підходах та реалізуються на різних вузлах паралельної системи, що дозволяє розширити покриття простору пошуку. Розроблений метод передбачає в процесі редукції даних оцінювання концентрованості контрольних точок навколо локальних екстремумів, яке засноване на просторовому розташуванні точок в поточній множині рішень, що дозволяє відстежувати надмірну концентрацію рішень в областях локальних оптимумів. Для підвищення рівномірності покриття простору пошуку в поточну множину рішень вводяться додаткові контрольні точки, розташовані поза зоною локальних оптимумів, що дозволяє підвищити різноманітність множини рішень поточної популяції. Застосування паралельних обчислень у запропонованому методі дозволяє скоротити час пошуку, і, як наслідок, збільшити практичний поріг застосовуваності методів відбору ознак при обробці великих обсягів даних.

8. Запропоновано модель подання стохастичного пошуку у ярусно-паралельній формі для параметричного синтезу нейро-нечітких мереж. Запропонована модель відрізняється використанням апріорної інформації про навчальну вибірку та просторове розташування рішень. Це дозволяє більш детально досліджувати області можливих оптимумів та скоротити час настроювання параметрів синтезованих діагностичних нейромоделей.

9. Розроблено метод параметричної ідентифікації нейро-нечітких мереж на основі паралельного випадкового пошуку, який для настроювання параметрів синтезованих моделей (параметри функцій належності та вагові коефіцієнти нейроелементів) використовує ймовірнісну оптимізацію, початкову множину рішень формує з урахуванням інформації про навчальну вибірку (враховується значущість термів ознак, використовуючи щільність розташування екземплярів навчальної множини у відповідному термі та ступінь його впливу на значення вихідного параметра), що дозволяє наблизити

початкові точки пошуку до областей розташування екстремумів і прискорити процес оптимізації. З метою більш детального дослідження областей локальних оптимумів у запропонованому методі виконується розбиття поточної множини рішень на підмножини з наступним пошуком оптимумів у кожній з них на відповідних процесах паралельної системи. При цьому формування відповідних підмножин відбувається таким чином, щоб кожен набір являв собою групу компактно розташованих рішень у просторі елементів (параметрів моделі), які налаштовуються, що дозволяє враховувати інформацію про просторове розташування рішень і більш детально досліджувати області розташування екстремальних рішень за допомогою випадкового пошуку. Розроблені оператори формування нової множини рішень враховують особливості розташування (діапазон значень) параметрів, що налаштовуються, їхній тип (параметри функцій належності нейронів, вагові коефіцієнти нейроелементів), пристосованість рішень-батьків, а також допускають вихід за межі відповідних діапазонів, що дозволяє розширювати область пошуку та виходити з можливих областей локальних екстремумів при синтезі діагностичних нейро-нечітких моделей.

10. Розроблено метод донавчання діагностичних нейро-нечітких моделей, який дозволяє адаптувати до зміни середовища функціонування існуючі моделі шляхом їх модифікації з урахуванням інформації, отриманої в результаті нових спостережень. Запропонований метод передбачає виконання етапів видобування та групування коригувальних екземплярів, діагностування за якими за допомогою існуючої моделі призводить до некоректних результатів, а також побудову коригувального блоку, який узагальнює дані коригувальних екземплярів, і впровадження його у вже існуючу модель. При визначенні параметрів, що настроюються, коригувального блоку в розробленому методі пропонується використовувати інформацію про значення координат коригувальних екземплярів, а також інформацію про ступінь їх належності до кластерів в просторі ознак (і, відповідно, нечітких правил,

представлених у коригувальному блоці). Це дозволяє врахувати значущість коригувальних екземплярів для відновлення функцій четвертого шару коригувального блоку і при визначенні параметрів, що настроюються, підвищити вклад тих екземплярів, які характеризуються високими оцінками ступеню належності конкретному кластеру. Використання запропонованого методу донавчання діагностичних нейро-нечітких моделей дозволяє не виконувати ресурсномісткий процес повторної побудови діагностичної моделі на основі повного набору даних, використовувати вже наявну модель в якості обчислювального блоку нової моделі. Крім того, моделі, синтезовані за допомогою запропонованого методу, характеризуються високою інтерпретовністю, оскільки кожен блок узагальнює інформацію про свій набір даних і в якості базису використовує нейро-нечіткі моделі.

11. Виконано експериментальне дослідження розроблених методів обробки даних та синтезу діагностичних моделей. Результати експериментів показали, що застосування запропонованих у дисертаційній роботі методів синтезу діагностичних моделей дозволило значно (в рази) підвищити швидкість побудови діагностичних моделей у порівнянні з методами, які передбачають послідовну реалізацію обчислень, а також збільшити рівні інтерпретовності та узагальнення даних за допомогою синтезованих моделей.

12. Практичні результати, отримані у дисертації, підтверджено актами впровадження та доводять коректність теоретичних положень дисертаційної роботи. Результати дисертаційної роботи апробовано та впроваджено на Державному підприємстві «Запорізьке машинобудівне конструкторське бюро «Прогрес» імені академіка О.Г. Івченка, Лубенському верстатобудівному заводі Акціонерного товариства «Мотор Січ», Публічному акціонерному товаристві «Запорізький металургійний комбінат «Запоріжсталь», Запорізькому державному медичному університеті, у практичну діяльність товариства з обмеженою відповідальністю «СофтХ», товариства з обмеженою відповідальністю «Науково-виробниче підприємство «Енергоальянс»,

товариства з обмеженою відповідальністю «Дніпро-Трейд», де використовуються для побудови діагностичних моделей технічних та медичних об'єктів. Наукові положення, висновки і рекомендації, викладені в дисертаційній роботі, використано при підготовці дисциплін «Інтелектуальні системи», «Основи обчислювального інтелекту», «Еволюційне моделювання» на кафедрі програмних засобів Національного університету «Запорізька політехніка».

Можливі напрями продовження досліджень за тематикою дисертації можуть бути пов'язані з розробленням методів синтезу діагностичних та розпізнавальних моделей на основі глибоких нейронних мереж для застосування та практичного використання у різних галузях науки і техніки, пов'язаних зі створенням інтелектуальних систем діагностування, зокрема у авіадвигунобудуванні, військовій промисловості, приладобудуванні, медицині тощо.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Ding, S. X. Model-based fault diagnosis techniques: design schemes, algorithms, and tools / S. X. Ding. – Berlin: Springer, 2008. – 473 p.
2. Gao, Z. A Survey of Fault Diagnosis and Fault-Tolerant Techniques—Part I: Fault Diagnosis With Model-Based and Signal-Based Approaches / Z. Gao, C. Cecati, S. X. Ding // IEEE Transactions on Industrial Electronics. – 2015. – Vol. 62, Issue 6. – P. 3757-3767.
3. Биргер, И. А. Техническая диагностика / И. А. Биргер. – М.: Машиностроение, 1978. – 240 с.
4. Gertler, J. Fault Detection and Diagnosis / J. Gertler // Encyclopedia of Systems and Control. – London: Springer-Verlag, 2015. – Vol. 1, Chapter 10. – 1554 p.
5. Сафарбаков, А.М. Основы технической диагностики : учеб. пособие / А. М. Сафарбаков, А. В. Лукьянов, С. В. Пахомов. – Иркутск: ИрГУПС, 2006. – 216 с.
6. Menyhart, J. Artificial Intelligence Applied for Technical Status Diagnostics of the Batteries of Automated Guided Vehicles / J. Menyhart, R. Szabolcsi // Military Technologies : International Conference, Brno, 30-31 May 2019 : Conference proceedings. – IEEE, 2019. – P. 1-8.
7. Diagnosis and fault-tolerant control / [M. Blanke, M. Kinnaert, J. Lunze, M. Staroswiecki]. – Berlin: Springer, 2006. – 672 p.
8. Gertler, J. Fault detection and diagnosis in engineering systems / J. Gertler. – New York: Marcel Dekker Inc., 1998. – 483 p.
9. Nelles, O. Nonlinear System Identification / O. Nelles. – Berlin : Springer, 2001. – 785 p.

10. Baron, P. Research and application of methods of technical diagnostics for the verification of the design node / P. Baron, M. Kocisko, J. Dobransky, M. Pollak, M. Teliskova // Measurement Volume. – 2016. – № 94. – P. 245-253.
11. Myslovych, M.V. Algorithms of operation and software of multilevel system for monitoring and technical diagnostics of electrical power facilities equipment / M.V.Myslovych, R.M.Sysak, L.B.Ostapchuk, Yu.I.Gyzhko, S.M.Hertsyk // Tekhnichna elektrodynamika. – 2016. – № 4. – P. 86-88.
12. Klyachkin, V.N. The use of aggregate classifiers in technical diagnostics, based on machine learning / V.N. Klyachkin, Yu.E. Kuvayskova, D.A. Zhukov // Information Technology and Nanotechnology : 3rd International conference, Samara, 24-27 April 2017 : CEUR Workshop Proceedings. – 2017. – Vol. 1903. – P. 32-35.
13. Rabkina, M. D. Analysis of results of technical diagnostics of shell-and-tube heat exchangers for ranking of service defects and evaluation of their effect on residual life / M. D. Rabkina, A. A. Perepichay, I. I. Perepichay, V. V. Mutas // Technical Diagnostics and Non-Destructive Testing. – 2017. – №2. – P. 50-54.
14. Gao, Z. A Survey of Fault Diagnosis and Fault-Tolerant Techniques—Part II: Fault Diagnosis With Knowledge-Based and Hybrid/Active Approaches / Z. Gao, C. Cecati, S. X. Ding // IEEE Transactions on Industrial Electronics. – 2015. – Vol. 62, Issue 6. – P. 3768-3774.
15. Химмельблау, Д. Обнаружение и диагностика неполадок в химических и нефтехимических процессах : [пер. с англ.] / Д. Химмельблау. – Л.: Химия, 1983. – 352 с.
16. Гуляев, В. А. Вычислительная диагностика / В. А. Гуляев. – К.: Наукова думка, 1992. – 232 с.
17. ASM handbook. – Vol. 17: Nondestructive evaluation and quality control. – Cleveland: ASM International, 1997. – 1607 p.
18. Price, C. Computer based diagnostic systems / C. Price. – London: Springer, 1999. – 136 p.

19. Serebryakov, A. New method of technical condition diagnostics of ship electric power plants / A. Serebryakov, A. Steklov, V. Titov // Power Drives Systems : IX International Conference, Perm, 3-7 October 2016 : Conference proceedings. – IEEE, 2016. – P. 85–88.
20. Flegner, P. An Advanced Method of Recognizing the State of the Technological Process in Technical Diagnostics / P. Flegner, J. Kacur, J. Terpak, M. Laciak, M. Durdan // Carpathian Control Conference : International Conference, Krakow-Wieliczka, 26–29 May 2019 : Conference proceedings. – IEEE, 2019. – P. 1–5.
21. Сударикова, Е. В. Неразрушающий контроль в производстве : учеб. пособие / Е. В. Сударикова. – Ч. 1. – СПб: СГУАП, 2007. – 137 с.
22. Deptula, A. Acoustic Diagnostics Applications in the Study of Technical Condition of Combustion Engine / A. Deptula, D. Kunderman, P. Osinski, U. Radziwanowska, R. Wlostowski // Archives of Acoustics. – 2016. – Vol. 41, Issue 2. – P. 345-350.
23. Vachtsevanos, G. Intelligent fault diagnosis and prognosis for engineering systems / G. Vachtsevanos, F. Lewis, M. Roemer et al. – New Jersey: John Wiley & Sons, 2006. – 434 p.
24. Sobhani-Tehrani, E. Fault diagnosis of nonlinear systems using a hybrid approach / E. Sobhani-Tehrani, K. Khorasani. – New York: Springer, 2009. – 265 p.
25. Технічне діагностування та контроль технічного стану. Терміни та визначення : ДСТУ 2389-94. – [Чинний від 1995-01-01]. – К.: Держстандарт України, 1994. – 24 с.
26. Korolev, P. G. Communication in technical diagnostics systems / P. G. Korolev, N. V. Romantsova, V. A. Sukhotski // Soft Computing and Measurements : XIX IEEE International Conference, St. Petersburg, 25-27 May 2016 : Conference proceedings. – IEEE, 2016. – P. 365-368.

27. Ardakani, M. H. Data driven methods for updating fault detection and diagnosis system in chemical processes :dissertation ... doctor of philosophy / M. H. Ardakani. – Barcelona : Universitat Politecnica de Catalunya, 2018. – 154 p.
28. Venkatasubramanian, V. A Review of Process Fault Detection and Diagnosis: Part I. Quantitative Model-Based Methods / V. Venkatasubramanian, R. Rengaswamy, K. Yin and S. N. Kavuri // *Computer and Chemical Engineering*. – 2003. – Vol. 27, Issue 3. – P. 293-311.
29. Mishra, M. Model-based Prognostics for Prediction of Remaining Useful Life :dissertation ... doctor of philosophy / Madhav Mishra. – Lulea, Sweden : Lulea University of Technology, 2015. – 102 p.
30. Opocenska, H. Use of technical diagnostics in predictive maintenance / H. Opocenska, M. Hammer // *Mechatronics – Mechatronika : International Conference, Prague, 7-9 December 2016*. – IEEE, 2016. – P. 317-322.
31. Orlov, S.P. Artificial Neural Network for Technical Diagnostics of Control Systems by Thermography / Orlov S.P., Girin R.V., Uyutova O. Yu. // *Industrial Engineering, Applications and Manufacturing : International Conference, Moscow, 15-18 May 2018*. – IEEE, 2018. – P. 1-4.
32. Kicinski, J. Non-linear Modelling of the Rotating Machine in Technical Diagnostics. The Concept of Adequacy Intervals and Weight Functions in the Identification Procedure / J. Kicinski // *Advances in Mechanism and Machine Science. Mechanisms and Machine Science*. – Springer, 2019. – Vol 73. – P. 3395-3409.
33. Yang, Q. Model-based and data driven fault diagnosis methods with applications to process monitoring : thesis ... doctor of philosophy / Yang Qingsong. – Cleveland: Case Western Reserve University, 2004. – 191 p.
34. Salfner, F. A survey of online failure prediction methods / F. Salfner, M. Lenk, M. Malek // *ACM computing surveys*. – 2010. – Vol. 42, Issue 3. – P. 1–42.
35. Denton, T. Advanced automotive fault diagnosis / T. Denton. – London: Elsevier, 2006. – 271 p.

36. Condition monitoring and diagnostics of machines — Data interpretation and diagnostics techniques — Part 1: General guidelines : ISO 13379-1:2012(en). — [First edition 2012-05-01]. — Geneva, Switzerland : International Organization for Standardization, 2012.

37. Handbook of Technical Diagnostics. Fundamentals and Application to Structures and Systems / Ed. Horst Czichos. — Berlin : Springer-Verlag, 2013. — 566 p.

38. Неразрушающий контроль : [в 5 кн.]. — М.: Высшая школа. — Кн. 2 : Акустические методы контроля : практ. пособие / И.Н. Ермолов, Н.П. Алешин, А.И. Потапов ; под ред. В.В. Сухорукова. — 1991. — 283 с.

39. Гуляев, В. А. Методы и средства обработки диагностической информации в реальном времени / В. А. Гуляев, В. М. Чаплыга, И. В. Кедровский. — К.: Наукова думка, 1986. — 224 с.

40. Ivanov, V.I Technical diagnostics in accident risk assessment / V.I. Ivanov, A.V. Kornilova, V.V. Musatov // Inorganic Materials. — 2016. — Vol. 52. — P. 1509–1514.

41. Alexandridis, A. A medical diagnostic tool based on radial basis function classifiers and evolutionary simulated annealing / A. Alexandridis, E. Chondrodima // Journal of Biomedical Informatics. — 2014. — Vol. 49. — P. 61–72.

42. Kanaev, A. K. Neural network model for the solution of tasks of technical diagnostics of the transport telecommunication network / A. K. Kanaev, M. A. Saharova, E. V. Beneta // Soft Computing and Measurements : XIX IEEE International Conference, St. Petersburg, 25-27 May 2016 : Conference proceedings. — IEEE, 2016. — P. 203-205.

43. Skupnik, D. Multifractals in Technical Diagnostics General Concept / D. Skupnik // In: Timofiejczuk A., Chaari F., Zimroz R., Bartelmus W., Haddar M. (eds) Advances in Condition Monitoring of Machinery in Non-Stationary Operations. Applied Condition Monitoring. — Springer, 2018. — P. 245-254.

44. Барсегян, А. А. Технологии анализа данных: Data Mining, Visual Mining, Text Mining, OLAP : учеб. пособие / А. А. Барсегян. – СПб: BHV, 2007. – 384 с.
45. Encyclopedia of artificial intelligence / Eds.: J. R. Dopico, J. D. de la Calle, A. P. Sierra. – New York : Information Science Reference, 2009. – Vol. 1–3. – 1677 p.
46. Sung, F. Learning to Compare: Relation Network for Few-Shot Learning / F. Sung, Y. Yang, L. Zhang, T. Xiang, P.H.S. Torr, T.M. Hospedales // Conference on Computer Vision and Pattern Recognition, Salt Lake City, USA, 18-23 June 2018 : proceedings. – IEEE, 2018. – P. 1199-1208.
47. Shin, Y.C. Intelligent systems : modeling, optimization, and control / C. Y. Shin, C. Xu. – Boca Raton: CRC Press, 2009. – 456 p.
48. Ukil, A. Intelligent Systems and Signal Processing in Power Engineering / A. Ukil. – Berlin: Springer, 2007. – 372 p.
49. Патрик, Э. Основы теории распознавания образов / Э. Патрик. – М.: Советское радио, 1980. – 408 с.
50. Федотов, Н.Г. Теория признаков распознавания образов на основе стохастической геометрии и функционального анализа / Н.Г. Федотов. – Москва : Физматлит, 2010. – 304 с.
51. Дубровин, В. И. Интеллектуальные средства диагностики и прогнозирования надежности авиадвигателей : монография / В. И. Дубровин, С. А. Субботин, А. В. Богуслаев, В. К. Яценко. – Запорожье: ОАО "Мотор-Сич", 2003. – 279 с.
52. Lin, T. Focal Loss for Dense Object Detection / T. Lin, P. Goyal, R. Girshick, K. He, P. Dollár // International Conference on Computer Vision (ICCV), Venice, Italy, 22-29 October 2017 : proceedings. – IEEE, 2017. – P. 2999-3007.
53. Duda, R. O. Pattern Classification / R. O. Duda, P. E. Hart, D. G. Stork. – New Jersey: John Wiley & Sons, 2000. – 680 p.

54. Ивахненко, А. Г. Моделирование сложных систем по экспериментальным данным / А. Г. Ивахненко, Ю. П. Юрачковский. – М.: Радио и связь, 1987. – 118 с.
55. Горелик, А. Л. Методы распознавания / А. Л. Горелик, В. А. Скрипкин. – М.: Высшая школа, 2004. – 261 с.
56. Dai, S. Fast and Accurate Estimation of Quality of Results in High-Level Synthesis with Machine Learning / S. Dai, Y. Zhou, H. Zhang, E. Ustun, E.F.Y. Young, Z. Zhang // 26th Annual International Symposium on Field-Programmable Custom Computing Machines (FCCM), Boulder, USA, 29 April-1 May 2018 : proceedings. – IEEE, 2018. – P. 129-132.
57. Computational intelligence in fault diagnosis / eds.: V. Palade, C.D. Bocaniala, L. Jain. – London: Springer, 2006. – 362 p.
58. Engelbrecht, A. Computational intelligence: an introduction / A. Engelbrecht. – Sidney : John Wiley & Sons, 2007. – 597 p.
59. Encyclopedia of machine learning / [eds. C. Sammut, G.I. Webb]. – New York: Springer, 2011. – 1031 p.
60. Sumathi, S. Computational Intelligence Paradigms: Theory & Applications using Matlab / S. Sumathi, S. Paneerselvam. – Boca Raton: CRC Press, 2010. – 851 p.
61. Russel, S. Artificial intelligence: a modern approach / S. Russel, P. Norvig. – New Jersey: Prentice Hall, 2009. – 1152 p.
62. Intelligent data analysis: an introduction / [eds. M. Berthold, D. J. Hand]. – New York: Springer Verlag, 2007. – 525 p.
63. Computational intelligence: collaboration, fusion and emergence / [ed. Ch. L. Mumford]. – New York: Springer, 2009. – 752 p.
64. Zhang, K. Beyond a Gaussian Denoiser: Residual Learning of Deep CNN for Image Denoising / K. Zhang, W. Zuo, Y. Chen, D. Meng, L. Zhang // Transactions on Image Processing. – 2017. – Vol. 26, № 7. – P. 3142-3155.

65. Clarke, B. Principles and theory for data mining and machine learning / B. Clarke, E. Fokoue, H. H. Zhang. – New York: Springer, 2009. – 781 p.
66. Wang, J. A Survey on Learning to Hash / J. Wang, T. Zhang, J. Song, N. Sebe, H.T. Shen // IEEE Transactions on Pattern Analysis and Machine Intelligence. – Vol. 40, № 4. – IEEE, 2018. – P. 769-790.
67. Bow, S. Pattern recognition and image preprocessing / S. Bow. – New York: Marcel Dekker Inc., 2002. – 698 p.
68. Ren, S. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks / S. Ren, K. He, R. Girshick, J. Sun // IEEE Transactions on Pattern Analysis and Machine Intelligence. – Vol. 39, № 6. – IEEE, 2017. – P. 1137-1149.
69. Rathore, S.S. A decision tree logic based recommendation system to select software fault prediction techniques / S. S. Rathore, S. Kumar // Computing. – Vol. 99. – Springer Link, 2017. – P. 255–285.
70. Kim, T. Incorporating receiver operating characteristics into naive Bayes for unbalanced data classification / T. Kim, B.D. Chung, J.S. Lee // Computing. – Vol. 99. – Springer Link, 2017. – P. 203-218.
71. Chen, W. Landslide spatial modeling: Introducing new ensembles of ANN, MaxEnt, and SVM machine learning techniques / W. Chen, H.R. Pourghasemi, A. Kornejady, N. Zhang // Geoderma. – Vol. 305 – Elsevier, 2017. – P. 314-327.
72. Fornara, N. Using Semantic Web Technologies and Production Rules for Reasoning on Obligations and Permissions / N. Fornara, A. Chiappa, M. Colombetti // Lecture Notes in Computer Science. – Vol. 11327. – Springer, 2018. – P. 49-63.
73. Hewahi, N.M. Concept based censor production rules / N.M. Hewahi // International Journal of Decision Support System Technology. – Vol.10, Issue 1. – Quarterly, 2018. – P. 59-67.
74. Fornara, N. Using Semantic Web technologies and production rules for reasoning on obligations, permissions, and prohibitions / N. Fornara, M. Colombetti // AI Communications. – Vol. 32, № 4. IOS Press, 2019. – P. 319-334.

75. Rokach, L. Data Mining with Decision Trees. Theory and Applications / L. Rokach, O. Maimon. – London : World Scientific Publishing Co, 2008. – 264 p.
76. Quinlan, J. R. Induction of decision trees / J. R. Quinlan // Machine Learning. – 1986. – № 1. – P. 81–106.
77. Bishop, C. Neural Networks for pattern recognition / C. Bishop. – New York: Oxford University Press, 1995. – 482 p.
78. Руденко, О. Г. Штучні нейронні мережі / О. Г. Руденко, Є. В. Бодяньський. – Харків: Компанія СМІТ, 2006. – 404 с.
79. Bodyanskiy, Ye. An evolving radial basis neural network with adaptive learning of its parameters and architecture / Ye. Bodyanskiy, A. K. Tyshchenko, A. Deineko // Automatic Control and Computer Sciences. – 2015. – Vol. 49, Issue 5. – P. 255-260.
80. Browne, A. Neural Network Analysis, Architectures and Applications / A. Browne. – Boca Raton : CRC Press, 1997. – 988 p.
81. Wen, T.H. A Network-based End-to-End Trainable Task-oriented Dialogue System / T.H. Wen, D. Vandyke, N. Mrksic, M. Gasic, L.M. Rojas-Barahona, P.H. Su, S. Ultes, S. Young // 15th Conference of the European Chapter of the Association for Computational Linguistics, Valencia, Spain, 3-7 April, 2017 : proceedings. – P. 438–449.
82. Belohlavek, R. Fuzzy Logic and Mathematics: A Historical Perspective / R. Belohlavek, G.J. Klir, J.W. Dauben. – Oxford: Oxford University Press, 2017. – 544 p.
83. Andres, C. Coevolutionary Fuzzy Modeling / C. Andres, P. Reyes. – Berlin: Springer, 2005. – 129 p.
84. Kandel, A. Fuzzy Control Systems / A. Kandel; G. Langholz. – Cleveland: CRC Press, 1993. – 656 p.
85. Яхьяева, Г. Э. Нечёткие множества и нейронные сети : учеб. пособие / Г. Э. Яхьяева. – М.: Интуит, 2006. – 316 с.

86. Pedrycz, W. Fuzzy modelling: paradigms and practice / W. Pedrycz. – Berlin : Springer, 1996. – 416 p.
87. Ротштейн, О. П. Діагностика на базі нечітких відношень в умовах невизначеності / О. П. Ротштейн, Г. Б. Ракитянська. – Вінниця: Універсум-Вінниця, 2006. – 275 с.
88. Classification and regression trees / L. Breiman, J. H. Friedman, R. A. Olshen, C. J. Stone. – California : Wadsworth & Brooks, 1984. – 368 p.
89. Quinlan, J. R. Decision trees and decision making / J. R. Quinlan // IEEE Transactions on Systems, Man and Cybernetics. – 1990. – № 2 (20). – P. 339–346.
90. Осовский, С. Нейронные сети для обработки информации / С. Осовский. – М.: Финансы и статистика, 2004. – 344 с.
91. Alvi, M. Turning a Blind Eye: Explicit Removal of Biases and Variation from Deep Neural Network Embeddings / M. Alvi, A. Zisserman, C. Nellåker // European Conference on Computer Vision, Munich, Germany, 8-14 September 2018 : proceedings. – Springer, 2018. – P. 556-572.
92. Rajalingham, R. Large-Scale, High-Resolution Comparison of the Core Visual Object Recognition Behavior of Humans, Monkeys, and State-of-the-Art Deep Artificial Neural Networks / R. Rajalingham, E.B. Issa, P. Bashivan, K. Kar, K. Schmidt, J.J. DiCarlo // Journal of Neuroscience. – Vol. 38, Issue 33. – JNeurosci, 2018. – P. 7255-7269.
93. Karras, T. Progressive Growing of GANs for Improved Quality, Stability, and Variation / T. Karras, T. Aila, S. Laine, J. Lehtinen // International Conference on Learning Representations (ICLR 2018), Vancouver, Canada, 26 April – 3 May 2018 : proceedings. – arXiv, 2018. – P. 26-52.
94. Jacob, B. Quantization and Training of Neural Networks for Efficient Integer-Arithmetic-Only Inference / B. Jacob, S. Kligys, B. Chen, M. Zhu, M. Tang et al. // Conference on Computer Vision and Pattern Recognition, Salt Lake City, USA, 18-23 June 2018 : proceedings. – IEEE, 2018. – P. 2704-2713.

95. Люгер, Дж. Ф. Искусственный интеллект: стратегии и методы решения сложных проблем / Дж. Ф. Люгер ; пер. с англ. – М.: Вильямс, 2005. – 864 с.
96. Rossi, A. Effective injury forecasting in soccer with GPS training data and machine learning / A. Rossi, L. Pappalardo, P. Cintia, F.M. Iaia, J. Fernández, D. Medina // PLOS ONE. – Vol.13, Issue 7. – PLOS, 2018. – P. 1-15.
97. Analysis and design of intelligent systems using soft computing techniques / eds.: P. Melin, O.R. Castillo, E.G. Ramirez, J. Kacprzyk. – Heidelberg: Springer, 2007. – 855 p.
98. Bishop, C.M. Pattern recognition and machine learning / C.M. Bishop. – New York: Springer, 2006. – 738 p.
99. Baykal, E. Automated nuclei detection in serous effusion cytology based on machine learning / E. Baykal, H. Doğan, M. Ekinici, M. E. Ercin, Ş. Ersöz // Signal Processing and Communications Applications Conference, Antalya, Turkey, 15-18 May 2017 : proceedings. – IEEE, 2017. – P. 1-4.
100. Chollet, F. Xception: Deep Learning with Depthwise Separable Convolutions / F. Chollet // Conference on Computer Vision and Pattern Recognition, Honolulu, USA, 21-26 July 2017 : proceedings. – IEEE, 2017. – P. 1800-1807.
101. Tenne, Y. Computational Intelligence in Expensive Optimization Problems / Y. Tenne, C.-K. Goh. – Berlin: Springer: 2010. – 800 p.
102. Yamankurt, G. Exploration of the nanomedicine-design space with high-throughput screening and machine learning / G. Yamankurt, E.J. Berns, A. Xue, A. Lee, N. Bagheri, M. Mrksich, C.A. Mirkin // Nature Biomedical Engineering. – Vol. 3, Issue 4. – Springer Nature, 2019. – P. 318-327.
103. Multivariate analysis, design of experiments, and survey sampling / ed. S. Ghosh. – New York: Marcel Dekker Inc., 1999. – 698 p.
104. Джессен, Р. Дж. Методы статистических обследований / Р.Д. Джессен ; пер. с англ. Ю. П. Лукашина, Я. Ш. Паппэ ; под ред. Е.М. Четыркина. – М.: Финансы и статистика, 1985. – 478 с.

105. Прикладная статистика: классификация и снижение размерности / [С. А. Айвазян, В. М. Бухштабер, И. С. Енюков, Л. Д. Мешалкин]. – М.: Финансы и статистика, 1989. – 607 с
106. Химмельблау, Д. Прикладное нелинейное программирование / Д. Химмельблау. – М.: Мир, 1974. – 534 с.
107. Encyclopedia of survey research methods / ed. P. J. Lavrakas. – Thousand Oaks: Sage Publications, 2008. – Vol. 1–2. – 968 p.
108. Ravindran, A. Engineering optimization: methods and applications / A. Ravindran, K. M. Ragsdell, G. V. Reklaitis. – New Jersey: John Wiley & Sons, 2006. – 688 p.
109. Chaudhuri, A. Survey sampling theory and methods / A. Chaudhuri, H. Stenger. – New York: Chapman & Hall, 2005. – 416 p.
110. Кокрен, У. Методы выборочного исследования / У. Кокрен ; пер. с англ. И. М. Сонины ; под ред. А. Г. Волкова, Н. К. Дружинина. – М.: Статистика, 1976. – 440 с.
111. Xu, H.K. Notes on a neural network approach to inverse variational inequalities / H.K. Xu, S. Dey, V. Vetrivel // Optimization. – Vol. 1. – Taylor & Francis Group, 2020. – P. 1–10.
112. Talbi, E. Metaheuristics: From Design to Implementation / E. Talbi. – Hoboken: John Wiley & Sons, 2009. – 624 p.
113. Lang, L. Study on the mining method for specific fault data of multimedia sensor networks in cloud computing environment / L. Lang, H. Yonghong, L. Xingming // Multimedia Tools and Applications. – Vol. 76, Issue 16. – Springer, 2017. – P. 17113-17128.
114. Nguyen, N.A. Data Reduction for Dynamic Stability Classification in Power System / N.A. Nguyen, T.N. Le, H.A. Quyen, T.T. Binh Phan // Iete Journal of Research. – Vol. 65, Issue 2. – Taylor & Francis Group, 2019. – P. 148-156.
115. Mumford, C. L. Computational Intelligence / C. L. Mumford, L. C. Jain. – Berlin : Springer-Verlag, 2009. – 732 p.

116. Hansen, M.H. Sample survey methods and theory / M. H. Hansen, W. N. Hertz, W. G. Madow. – Vol. 1 : Methods and applications. – New York: John Wiley & Sons, 1953. – 638 p.
117. Yaqoob, I. Big data: From beginning to future / I. Yaqoob, I. A. Hashem, A. Gani, S. Mokhtar, E. Ahmed, N. B. Anuar, A. V. Vasilakos // International Journal of Information Management. – 2016. – Vol. 36, Issue 6. – P. 1231–1247.
118. Manyika, J. Big data: The next frontier for innovation, competition, and productivity / J. Manyika, M. Chui, B. Brown, J. Bughin, R. Dobbs, C. Roxburgh, A. H. Byers. – Seoul : McKinsey Global Institute, 2011. – 146 p.
119. Mayer-Schönberger, V. Big data : a revolution that will transform how we live, work and think / V. Mayer-Schönberger, K. Cukier. – London : John Murray (Publishers), 2013. – 242 p.
120. Wu, X. Data mining with big data / X. Wu, X. Zhu, G. Wu, W. Ding // IEEE Transactions on Knowledge and Data Engineering. – 2014. – Vol. 26, Issue 1. – P. 97–107.
121. Chen, M. Big Data: A Survey / M. Chen, S. Mao, Y. Liu // Mobile Networks and Applications. – 2014. – Vol. 19, Issue 2. – P. 171–209.
122. McAfee, A. Big data: the management revolution / A. McAfee, E. Brynjolfsson // Harvard Business Review. – 2012. – Vol. 90, Issue 10. – P. 1–60.
123. Xu, L.D. Internet of Things in Industries: A Survey / L.D. Xu, W. He, S. Li // IEEE Transactions on Industrial Informatics. – 2014. – Vol. 10, Issue 4. – P. 2233–2243.
124. Al-Fuqaha, A. Internet of Things: A Survey on Enabling Technologies, Protocols, and Applications / A. Al-Fuqaha, M. Guizani, M. Mohammadi, M. Aledhari and M. Ayyash // IEEE Communications Surveys & Tutorials. – 2015. – Vol. 17, Issue. 4. – P. 2347–2376.

125. Chen, H. Business intelligence and analytics: from big data to big impact / H. Chen, R. Chiang, V. Storey // *Management Information Systems Quarterly*. – 2012. – Vol. 36, Issue 4. – P. 1165–1188.

126. Subbotin, S. The Dimensionality Reduction Methods Based on Computational Intelligence in Problems of Object Classification and Diagnosis / S. Subbotin, A. Oliinyk // *Recent Advances in Systems, Control and Information Technology. Advances in Intelligent Systems and Computing*. – 2017. – Vol. 543. – P. 11–19.

127. Rummel, R. J. *Applied Factor Analysis* / R. J. Rummel. – Evanston : Northwestern University Press. – 1988. – 617 p.

128. Иберла, К. Факторный анализ / К. Иберла. – М. : Статистика. – 1980. – 398 с.

129. Jolliffe, I. T. *Principal Component Analysis* / I. T. Jolliffe // *International Encyclopedia of Statistical Science*. – 2014. – P. 1094–1096.

130. McLachlan, G. *Discriminant Analysis and Statistical Pattern Recognition* / G. McLachlan. – New Jersey : John Wiley & Sons. – 2004. – 526 p.

131. Jensen, R. *Computational intelligence and feature selection: rough and fuzzy approaches* / R. Jensen, Q. Shen. – Hoboken: John Wiley & Sons, 2008. – 339 p.

132. Lee, J.A. *Nonlinear dimensionality reduction* / J.A. Lee, M. Verleysen. – New York: Springer, 2007. – 308 p.

133. Koh, Y. S. *Rare Association Rule Mining and Knowledge Discovery* / Y. S. Koh, N. Rountree. – New York : Information Science Reference. – 2009. – 320 p.

134. Adamo, J.-M. *Computational Structures and Algorithms for Association Rules: The Galois Connection* / J.-M. Adamo. – Seattle : Createspace. – 2011. – 276 p.

135. Petrzala, L. Discovery of Association Rules in Datasets Via Evolutionary Algorithms / L. Petrzala. – Hamburg : Lambert Academic Publishing. – 2014. – 96 p.
136. Agrawal, J. A Novel PSO Based Approach for Mining Association Rules / J. Agrawal, S. Agrawal, A. Singhai. – Hamburg : Lambert Academic Publishing. – 2013. – 76 p.
137. Zhang, C. Association rule mining: models and algorithms / C. Zhang, S. Zhang. – Berlin : Springer-Verlag. – 2002. – 238 p.
138. Gkoulalas-Divanis, A. Association Rule Hiding for Data Mining / A. Gkoulalas-Divanis, V. S. Verykios. – New York : Springer-Verlag. – 2010. – 150 p.
139. Zhao, Y. Post-mining of association rules: techniques for effective knowledge extraction / Y. Zhao, C. Zhang, L. Cao. – New York : Information Science Reference. – 2009. – 372 p.
140. Adamo, J.-M. Data mining for association rules and sequential patterns: sequential and parallel algorithms / J.-M. Adamo. – New York : Springer-Verlag. – 2001. – 259 p.
141. Rauch, J. Observational Calculi and Association Rules / J. Rauch. – Berlin : Springer-Verlag. – 2013. – 296 p.
142. Хайкин, С. Нейронные сети: полный курс / С. Хайкин. – СПб: Вильямс, 2005. – 1104 с.
143. Милов, В. Р. Структурно-параметрический синтез нейросетевых систем обработки информации : дис. ... д-ра техн. наук : 05.13.01 / Милов Владимир Ростиславович. – Нижний Новгород, 2003. – 310 с.
144. Van Veen, F. The Neural Network Zoo [Electronic resource] / F. Van Veen. – Access mode: <https://www.asimovinstitute.org/neural-network-zoo>.
145. Liao, L. Attributed Social Network Embedding / L. Liao, X. He, H. Zhang, T. Chua // Transactions on Knowledge and Data Engineering. – Vol. 30, № 12. – IEEE 2018. – P. 2257–2270.

146. Musumeci, F. An Overview on Application of Machine Learning Techniques in Optical Networks / F. Musumeci, C. Rottondi, A. Nag, I. Macaluso et al. // *Communications Surveys & Tutorials*. – Vol. 21, № 2. – IEEE, 2019. – P. 1383–1408.
147. Lamb, A. Interpolated Adversarial Training: Achieving Robust Neural Networks Without Sacrificing Too Much Accuracy / A. Lamb, V. Verma, J. Kannala, Y. Bengio // *Workshop on Artificial Intelligence and Security, London, UK, 15 November 2019 : proceedings*. – P. 95-103.
148. Kutz, J.N. Deep learning in fluid dynamics / J.N. Kutz // *Journal of Fluid Mechanics*. – Vol. 814. – Cambridge University Press, 2017. – P. 1–4.
149. Gebali, F. Algorithms and Parallel Computing / F. Gebali. – New Jersey: John Wiley & Sons, 2011. – 364 p.
150. Roosta, S.H. Parallel Processing and Parallel Algorithms: Theory and Computation. Springer-Verlag, NY, 2000. – 566 p.
151. Quinn, M.J. Parallel Programming in C with MPI and OpenMP / M.J. Quinn. – New York, NY: McGraw-Hill, 2004. – 529 p.
152. NVIDIA Corporation. NVIDIA CUDA Compute Unified Device Architecture 5.5 / NVIDIA Corporation. : NVIDIA, 2014. – 117 p.
153. McCool, M. Structured Parallel Programming: Patterns for Efficient Computation / M. McCool, J. Reinders, A. Robison. – Boston : Morgan Kaufmann, 2012. – 432 p.
154. Fokkink, W. Distributed Algorithms: An Intuitive Approach / Wan Fokkink. – Cambridge : MIT Press, 2013. – 248 p.
155. Herlihy, M. The Art of Multiprocessor Programming Revised Reprint / M. Herlihy, N. Shavit. – Boston : Morgan Kaufmann, 2012. – 536 p.
156. Параллельные вычисления. Технологии и численные методы. Учебное пособие в 4 томах / [Гергель В.П., Баркалов К.А., Мееров И.Б., Сысоев А.В. и др.]. – Нижний Новгород: Изд-во Нижегородского государственного университета, 2013. – 1394 с.

157. Zhang, H. Parallel implementation of multilayered neural networks based on Map-Reduce on cloud computing clusters / H. Zhang, N. Xiao // *Soft Computing*. – 2016. – Vol. 20, Issue 4. – P. 1471–1483.
158. Kirk, D. *Programming Massively Parallel Processors 3rd Edition. A Hands-on Approach* / D. Kirk, Hwu Wen-mei, 2016. – 576 p.
159. Pavlo, A. A comparison of approaches to large-scale data analysis / Andrew Pavlo, Erik Paulson, Alexander Rasin, Daniel J. Abadi, David J. DeWitt // *International Conference on Management of Data*. – 2009. – PP. 165–178.
160. Barroso, L.A. *The Datacenter as a Computer: An Introduction to the Design of Warehouse-Scale Machines* / Luiz Andre Barroso, Urs Hoelzle // *Synthesis Lectures on Computer Architecture*, volume 4, issue 1, 2009. – 154 p.
161. Mahmood, Z. *Data Science and Big Data Computing: Frameworks and Methodologies* / Zaigham Mahmood // Springer International Publishing. – 2016. – 332 p.
162. Creel, M. *Multi-core CPUs, Clusters, and Grid Computing: A Tutorial* / Michael Creel, William L. Goffe // *Computational Economics*, 2008. – volume 32, issue 4. – P. 353-382.
163. Gupta, K. A study of Persistent Threads style GPU programming for GPGPU workloads / Kshitij Gupta, Jeff A. Stuart, John D. Owens // *Parallel Computing*, 2012. – P. 1–14.
164. Mo, H. *Handbook of research on artificial immune systems and natural computing: applying complex adaptive technologies* / H. Mo. – London: Information Science Reference, 2009. – 634 p.
165. Dasgupta, D. *Immunological computation: theory and applications* / D. Dasgupta, F. Nino. – Boca Raton: Auerbach Publications, 2008. – 296 p.
166. Ishida, Y. *Immunity-based systems: a design perspective* / Y. Ishida. – Berlin: Springer, 2004. – 177 p.

167. Tarakanov, A. O. Immunocomputing: principles and applications / A. O. Tarakanov, V. A. Skormin, S. P. Sokolova. – New York: Springer, 2003. – 230 p.
168. Segel, L.A. Design principles for immune system and other distributed autonomous systems / L. A. Segel, I. R. Cohen. – New York: Oxford University Press, 2001. – 428 p.
169. Flower, D. In silico immunology / D. Flower, J Timmis. – New York: Springer, 2007. – 451 p.
170. Wierzchoń, S. T. Sztuczne systemy immunologiczne. Teoria i zastosowania / S. T. Wierzchoń. – Warszawa: Akademicka Oficyna Wydawnicza Exit, 2001. – 282 s.
171. Dasgupta, D. Artificial immune systems and their applications / D. Dasguta. – New York: Springer-Verlag, 1998. – 306 p.
172. De Castro, L. N. Artificial immune systems: a new computational intelligence approach / L. N. de Castro, J Timmis. – New York: Springer-Verlag, New York, 2002. – 380 p.
173. Ong, A. An adaptive anomaly detection system using data mining and artificial immune system / A. Ong. – London: King's College London, 2007. – 348 p.
174. Ji, Z. Revisiting negative selection algorithms / Z. Ji, D. Dasgupta // Evolutionary Computation. – 2007. – Vol. 15. – P. 223–251.
175. A feedback negative selection algorithm to anomaly detection / J. Zeng, T. Li, X. Liu [et al.] // Natural Computation: Third International Conference ICNC-2007, Haikou, 24-27 August 2007: proceedings. Vol. 3. – Los Alamitos: IEEE Computer Society, 2007. – P. 604–608.
176. Zhang, P. T. A malware detection model based on a negative selection algorithm with penalty factor / P. T. Zhang, W. Wang, Y. Tan // Science China. Information sciences. – 2010. – Vol. 53. № 12. – P. 2461–2471.

177. Oliveira, L. O. Real-valued negative selection (RNS) for classification task / L. O. Oliveira, I. N. Drummond // *Recognizing patterns in signals, speech, images and videos.* – 2010. – Vol. 6388. – P. 66–74.

178. Ji, Z. A boundary-aware negative selection algorithm / Z. Ji // *Artificial Intelligence and Soft Computing: 9th International Conference of International Association of Science and Technology for Development ASC-2005, Benidorm, 12-14 September 2005: proceedings.* – Los Alamitos: IEEE Computer Society, 2005. – P. 49–55.

179. Ji, Z. Negative selection algorithms: from the thymus to V-detector : thesis ... doctor of philosophy in "Computer Science" / Zhou Ji. – Memphis, 2006. – 337 p.

180. Zaitsev, S. A. Negative selection using masked detectors / S. A. Zaitsev, S. A. Subbotin // *Моделирование неравновесных систем : XIV Всероссийский семинар, Красноярск, 7-9 октября 2011 г.: материалы.* – Красноярск: СФУ, 2011. – С. 95–98.

181. A new cluster based real negative selection algorithm / W. Chen, T. Li, J. Qin [et al.] // *Information and automation.* – 2011. – Vol. 86. – P. 125–131.

182. Esponda, F. Negative representations of information / F. Esponda, S. Forrest, P. Helman // *International Journal of Information Security.* – 2009. – Vol. 8, № 5. – P. 331–345.

183. Gonzalez, F. The effect of binary matching rules in negative selection / F. Gonzalez, D. Dasgupta, J. Gomez // *Genetic and Evolutionary Computation: conference GECCO-2003, Chicago, 9–11 July 2003: proceedings.* – Berlin-Heidelberg: Springer-Verlag, 2003. – P. 195–206.

184. Ong, A. An adaptive anomaly detection system using data mining and artificial immune system / A. Ong. – London: King's College London, 2007. – 348 p.

185. Gonzalez, F. A. Anomaly detection using real-valued negative selection / F. A. Gonzalez, D. Dasgupta // *Journal of Genetic Programming and Evolvable Machines.* – 2003. – Vol. 4, № 4. – P. 383–403.

186. Chmielewski, A. Simple method of increasing the coverage of nonself region for negative selection algorithms / A. Chmielewski, S.T. Wierzchon // Computer Information Systems and Industrial Management Applications: 6th International Conference CISIM'07, Elk, 28–30 June 2007: proceedings. – Los Alamitos: IEEE Computer Society, 2007. – P. 155–160.

187. Stibor, T. On the use of hyperspheres in artificial immune systems as antibody recognition regions / T. Stibor, J. Timmis, C. Eckert // Artificial Immune Systems: Fifth International Conference ICARIS-2006, Oeiras, 4–6 September 2006: proceedings. – New York: Springer Verlag, 2006. – P. 215–228.

188. Molenberghs, G. Missing Data in Clinical Studies / G. Molenberghs, M.G. Kenward. – Chichester : John Wiley and Sons Ltd, 2007. – 504 p.

189. Burton, A. Missing covariate data within cancer prognostic studies: A review of current reporting and proposed guidelines / A. Burton, D. Altman // British Journal of Cancer. – 2004. – Vol. 91, Issue 1. – P. 4–8.

190. Horton, N.J. Much ado about nothing: A comparison of missing data methods and software to fit incomplete data regression models / N.J. Horton, K.P. Kleinman // American Statistician. – 2007. – Vol. 61. – P. 79–90.

191. Graham, J. Missing Data: Analysis and Design / J. Graham. – New York : Springer, 2012. – 325 p.

192. Глушко, О. Обработка пропусков в данных [Электронный ресурс] / О. Глушко. – Режим доступа: <https://basegroup.ru/community/articles/missing> .

193. Ware, J.H. Missing data / J.H. Ware, D. Harrington, D. J. Hunter, R.B. D'Agostino // New England Journal of Medicine. – 2012. – Vol. 367. – P. 1353–1354.

194. Enders, C. Applied Missing Data Analysis / C. Enders. – New York : The Guilford Press, 2010. – 382 p.

195. Guyon, I. An introduction to variable and feature selection / I. Guyon, A. Elisseeff // Journal of machine learning research. – 2003. – № 3. – P. 1157–1182.

196. Hyvarinen, A. Independent component analysis / A. Hyvarinen, J. Karhunen, E. Oja. – New York: John Wiley & Sons, 2001. – 481 p.
197. Jensen, R. Combining rough and fuzzy sets for feature selection : thesis ... doctor of philosophy / Jensen Richard. – Edinburgh: University of Edinburgh, 2005. – 221 p.
198. Abonyi, J. Cluster analysis for data mining and system identification / J. Abonyi, B. Feil. – Basel: Birkhäuser, 2007. – 303 p.
199. Kononenko, I. Estimating Attributes: Analysis And Extensions Of Relief / I. Kononenko // Machine Learning : European Conference on Machine Learning ECML-94, Catania, 6-8 April 1994 : proceedings of the conference. – Berlin : Springer, 1994. – P. 171–182.
200. Kira, K. A practical approach to feature selection / K. Kira, L. Rendell // Machine Learning : International Conference on Machine Learning ML92, Aberdeen, 1-3 July 1992 : proceedings of the conference. – New York: Morgan Kaufmann, 1992. – P. 249–256.
201. Sato, S. Text-Data Reduction Method to Grasp the Sequence of a Disaster Situation: Case Study of Web News Analysis of the 2015 Typhoons 17 and 18 / S. Sato, T. Okamoto, S. Koshimura // Journal of disaster research. – Vol. 12, Issue 2. – Fuji Technology Press, 2017. – P. 329-334.
202. Васильев, В. И. Принцип редукции в задачах обнаружения закономерностей : монография / В.И. Васильев, А.И. Шевченко, С.Н. Эш. – Донецк: Наука і освіта, 2009. – 340 с.
203. Yu, S. Feature selection and classifier ensembles: a study on hyperspectral remote sensing data : proefschrift ... doctor in de wetenschappen / Yu Shixin. – Antwerpen: Universitaire Instelling Antwerpen, 2003. – 124 p.
204. The Practical Handbook of Genetic Algorithms / ed. L. D. Chambers. – Florida: CRC Press, 2000. – Vol. I: Applications. – 520 p.
205. Скобцов, Ю. А. Основы эволюционных вычислений / Ю. А. Скобцов. – Донецк: ДонНТУ, 2008. – 330 с.

206. Олійник, А. О. Еволюційні обчислення та програмування : навчальний посібник / А. О. Олійник, С. О. Субботін, О. О. Олійник. – Запоріжжя : ЗНТУ, 2010. – 324 с.
207. Nissen, V. A Brief Introduction to Evolutionary Algorithms from the Perspective of Management Science / V. Nissen // Innovative Research Methodologies in Management. – 2018. – P. 165–210.
208. Ayala, H. V. Cascaded evolutionary algorithm for nonlinear system identification based on correlation functions and radial basis functions neural networks / H. V. Ayala, L. D. Coelho // Mechanical Systems and Signal Processing. – 2016. – Vol. 68, Issue 6. – P. 3768–378.
209. Pagliuca, P. Maximizing adaptive power in neuroevolution / P. Pagliuca, N. Milano, S. Nolfi // PLoS ONE. – 2018. – Vol. 13, № 7. – P. 1–27.
210. Petroski Such, F. Deep Neuroevolution: Genetic Algorithms Are a Competitive Alternative for Training Deep Neural Networks for Reinforcement Learning / F. Such Petroski, V. Madhavan, E. Conti, J. Lehman, K. Stanley, J. Clune, Jeff // Technical report 1712.06567. – 2017. – P. 1–16.
211. Gen, M. Genetic algorithms and engineering design / M. Gen, R. Cheng. – New Jersey: John Wiley & Sons, 1997. – 352 p.
212. Abraham, A. Swarm intelligence in data mining / A. Abraham, G. Grosan. – Berlin: Springer, 2006. – 267 p.
213. Dorigo, M. Optimization, learning and natural algorithms / M. Dorigo. – Milano: Politecnico di Milano, 1992. – 140 p.
214. Dorigo, M. Ant algorithms solve difficult optimization problems / M. Dorigo // Advances in artificial life : Sixth European conference, 10-14 September 2001, Prague: proceedings. – Berlin: Springer, 2001. – P. 11–22.
215. Kim, D. H. Bacterial foraging based neural network fuzzy learning / D. H. Kim, C. H. Cho // Artificial intelligence : second Indian international conference, 20-22 December 2005 : proceedings / ed. B. Prasad. – Pune : IICAI, 2005. – P. 2030–2036.

216. Kim, D. H. A hybrid genetic algorithm and bacterial foraging approach for global optimization / D. H. Kim, A. Abraham, J. H. Cho // *Information sciences*. – 2007. – Vol.177, № 18. – P. 3918–3937.

217. Гибридные нейро-фаззи модели и мультиагентные технологии в сложных системах: монография / [В.А. Филатов, Е.В. Бодянский, В.Е. Кучеренко и др.] ; под общ. ред. Е.В. Бодянского. – Дніпропетровськ: Системні технології, 2008. – 403 с.

218. He, W. Adaptive Fuzzy Neural Network Control for a Constrained Robot Using Impedance Learning / W. He, Y. Dong // *Transactions on Neural Networks and Learning Systems*. – Vol. 29, № 4. – IEEE, 2018. – P. 1174-1186.

219. Методы робастного, нейро-нечеткого и адаптивного управления: учебник / под ред. Н.Д. Егупова. – М.: МГТУ им. Н.Э. Баумана, 2001. – 744 с.

220. Tickle, A. B. Rule Extraction From Trained Artificial Neural Networks / A. B. Tickle, R. Andrews, M. Golea, J. Diederich // *Neural Network Analysis, Architectures and Applications*. – Boca Raton : CRC Press, 1997. – P. 61–72.

221. GopiKrishna, T. Evaluation of rule extraction algorithms / T. GopiKrishna // *International Journal of Data Mining & Knowledge Management Process (IJDMP)*. – 2014. – Vol. 4, Issue 3. – P. 9–19.

222. Lu, H. Neurorule: A connectionist approach to data mining / H. Lu, R. Setino, H. Liu // *VLDB: Proceedings of the International Very Large Databases Conference, 11 – 15 September 1995 : proceedings of the conference*. – San Francisco : Morgan Kaufmann Publishers Inc., 1995. – P. 478–489.

223. Kadhim, M. A. A Multi-intelligent Agent Architecture for Knowledge Extraction: Novel Approaches for Automatic Production Rules Extraction / M. A. Kadhim, M. A. Alam, H. Kaur // *International Journal of Multimedia and Ubiquitous Engineering*. – 2014. – Vol. 9, Issue 2. – P. 95–114.

224. Quinlan, J. R. Generating production rules from decision trees / J. R. Quinlan // *IJCAI Proceedings of the 10th international joint conference on Artificial*

intelligence, 23 – 29 August 1987 : proceedings of the conference. – San Francisco : Morgan Kaufmann Publishers Inc., 1987. – P. 304–307.

225. Liu, B. Integrating Classification and Association Rule Mining / B. Liu, W. Hsu, Y. Ma // KDD Proceedings of the Fourth International Conference on Knowledge Discovery and Data Mining, 27 – 31 August 1998 : proceedings of the conference. – New York : AAAI Press, 1998. – P. 80–86.

226. Craven, M. Using Neural Networks for Data Mining / M. Craven, J. Shavlik // Future Generation Computer Systems. – 1997. – Vol. 13. – P. 211–229.

227. Kadhim, M. A. A Multi-intelligent Agent Architecture for Knowledge Extraction: Novel Approaches for Automatic Production Rules Extraction / M.A. Kadhim, M.A. Alam, H. Kaur // International Journal of Multimedia and Ubiquitous Engineering. – 2014. – Vol 9, Issue 2. – P. 95–114.

228. Dorado, J. Automatic Recurrent and Feed-Forward ANN Rule and Expression Extraction with Genetic Programming / J. Dorado, J. R. Rabunãl, A. Santos, A. Pazos, D. Rivero // Proceedings of the 7th International Conference on Parallel Problem Solving from Nature, 7 – 11 September 2002 : proceedings of the conference. – Berlin : Springer-Verlag, 2002. – P. 80–86.

229. Wang, Y. Dissipativity-Based Fuzzy Integral Sliding Mode Control of Continuous-Time T-S Fuzzy Systems / Y. Wang, H. Shen, H.R. Karimi, D. Duan // Transactions on Fuzzy Systems. – Vol. 26, № 3. – IEEE, 2018. – P. 1164–1176.

230. Oliveira, R.F. Estimation of respiratory frequency and rectal temperature on pigs in heat stress by fuzzy logic / R.F. Oliveira, R.A. Ferreira, L.H.P. Abreu, T. Yanagi Júnior, D. Lourençoni // Engenharia Agricola. – Vol. 38, Issue 4. – SCImago, 2018. – P. 457–470.

231. Abdul-Wahab, S.A. Prediction of optimum sampling rates of air quality monitoring stations using hierarchical fuzzy logic control system / S.A. Abdul-Wahab, Y. Charabi, S. Osman, K. Yetilmezsoy, I.I. Osman // Atmospheric Pollution Research. – Vol. 10, Issue 6. – Elsevier, 2019. – P. 1931–1943.

232. Amezcua, J. Classification of Arrhythmias Using Modular Architecture of LVQ Neural Network and Type 2 Fuzzy Logic / J. Amezcua, P. Melin // *Nature-Inspired Design of Hybrid Intelligent Systems*. – Vol. 667 – Springer, 2017. – P. 187–194.

233. Борисов, В. В. Нечёткие модели и сети / В.В. Борисов, В. В. Круглов, А. С. Федулов. – М.: Горячая линия-Телеком, 2007. – 284 с.

234. Neural and fuzzy logic control of drives and power systems / [M.N. Cirstea, A. Dinu, J.G. Khor, M. McCormick]. – Oxford: Newnes, 2002. – 399 p.

235. Bordon, J. Semi-quantitative Modelling of Gene Regulatory Processes with Unknown Parameter Values Using Fuzzy Logic and Petri Nets / J. Bordon, M. Moškon, N. Zimic, M. Mraz // *Fundamenta Informaticae*. – Vol. 60. – IOS Press, 2018. – P. 81–100.

236. Jin, L. Manipulability Optimization of Redundant Manipulators Using Dynamic Neural Networks / L. Jin, S. Li, H. M. La, X. Luo // *Transactions on Industrial Electronics*. – Vol. 64, № 6. – IEEE, 2017. – P. 4710–4720.

237. Gers, F.A. Learning to Forget: Continual Prediction with LSTM / F.A. Gers, J.A. Schmidhuber, F.A. Cummins // *Neural Computation*. – 2000. – Vol. 12, Issue 10. – P. 2451–2471.

238. Fu, R. Using LSTM and GRU neural network methods for traffic flow prediction / R. Fu, Z. Zhang, L. Li // *Youth Academic Annual Conference of Chinese Association of Automation: IEEE Conference, Wuhan, China, 11-13 November 2016 : Conference proceedings*. – IEEE, 2016. – P. 324–328.

239. Schuster, M. Bidirectional recurrent neural networks / M. Schuster, K.K. Paliwal // *IEEE Transactions on Signal Processing*. – 1997. – Vol. 45, Issue 11. – P. 2673–2681.

240. Vincent, P. Stacked Denoising Autoencoders: Learning Useful Representations in a Deep Network with a Local Denoising Criterion / P. Vincent, H.

Larochelle, I. Lajoie, Y. Bengio, P. Manzagol // *Journal of Machine Learning Research*. – 2010. – Vol. 11. – P. 3371-3408.

241. Goodfellow, I. *Deep Learning (Adaptive Computation and Machine Learning series)* / I. Goodfellow, Y. Bengio, A. Courville / London : The MIT Press, 2016. – 775 p.

242. Handa, A. *Backpropagation in convolutional LSTMS* / A. Handa, V. Patraucean // *University of Cambridge*. – 2015. – P. 1–5.

243. Creswell, A. *Generative Adversarial Networks: An Overview* / A. Creswell, T. White, V. Dumoulin, et. al. // *IEEE Signal Processing Magazine*. – 2018. – Vol. 35, Issue 1. – P. 53–65.

244. Huang, G. *Extreme learning machines: a survey* / G. Huang, D. Wang, Y. Lan // *International Journal of Machine Learning and Cybernetics*. – 2011. – Vol. 2, Issue 2. – P. 107–122.

245. Tang, J. *An Improved Fuzzy Neural Network for Traffic Speed Prediction Considering Periodic Characteristic* / J. Tang, F. Liu, Y. Zou, W. Zhang, Y. Wang // *Transactions on Intelligent Transportation Systems*. – Vol. 18, № 9. IEEE, 2017. – P. 2340-2350.

246. Deng, Y. *A Hierarchical Fused Fuzzy Deep Neural Network for Data Classification* / Y. Deng, Z. Ren, Y. Kong, F. Bao, Q. Dai // *Transactions on Fuzzy Systems*. – Vol. 25, № 4. – IEEE, 2017. P. 1006-1012.

247. Dhimish, M. *Comparing Mamdani Sugeno fuzzy logic and RBF ANN network for PV fault detection* / M. Dhimish, V. Holmes, B. Mehrdadi, M. Dales // *Renewable Energy*. – Vol. 117. – Elsevier, 2018. – P. 257-274.

248. Bodyanskiy, Ye. *Hybrid adaptive wavelet-neuro-fuzzy system for chaotic time series identification* / Ye. Bodyanskiy, O. Vynokurova // *Information Sciences*. – 2013. – Vol. 220. – P. 170–179.

249. Jang, J. R. *ANFIS: Adaptive-network-based fuzzy inference system* / J. R. Jang // *IEEE transactions on systems and cybernetics*. – 1993. – Vol. 23. – P. 665–685.

250. Jang, J.R. Neuro-fuzzy and soft computing: a computational approach to learning and machine intelligence / J. R. Jang, C.-T. Sun, E. Mizutani. – Upple Saddle River: Prentice-Hall, 1997. – 614 p.
251. Nauck, D. Foundations of neuro-fuzzy systems / D. Nauck, F. Klawonn, R. Kruse. – Chichester : John Wiley & Sons, 1997. – 305 p.
252. Rutkowski, L. Flexible neuro-fuzzy systems : structures, learning and performance evaluation / L. Rutkowski. – Boston: Kluwer, 2004. – 276 p.
253. Бодянский, Е. В. Нейро-фаззи сети Петри в задачах моделирования сложных систем / Е. В. Бодянский, Е. И. Кучеренко, А. И. Михалев. – Днепропетровск: Системные технологии. – 2005. – 311 с.
254. Бодяньський, Є. В. Нейро-фаззі моделі в системах штучного інтелекту : навч. посібник / Є. В. Бодяньський, Є. І. Кучеренко. – Харків: ХНУРЕ, 2006. – 196 с.
255. Suzuki, K. Artificial Neural Networks: Architectures and Applications / K. Suzuki. – New York : InTech, 2013. – 264 p.
256. Hanrahan, G. Artificial Neural Networks in Biological and Environmental Analysis / G. Hanrahan. – Boca Raton, Florida : CRC Press, 2011. – 214 p.
257. Shokouhifar, M. Optimized sugeno fuzzy clustering algorithm for wireless sensor networks / M. Shokouhifar, A. Jalali // Engineering Applications of Artificial Intelligence. – Vol. 60. – Elsevier, 2017. – P. 16–25.
258. Zuo, H. Fuzzy Regression Transfer Learning in Takagi–Sugeno Fuzzy Models / H. Zuo, G. Zhang, W. Pedrycz, V. Behbood, J. Lu // Transactions on Fuzzy Systems. – Vol. 25, № 6. – IEEE, 2017. – P. 1795–1807.
259. Kaur, J. An Enhanced Approach for Attack Detection in VANETs Using Adaptive Neuro-Fuzzy System / J. Kaur, T. Singh, K. Lakhwani // International Conference on Automation, Computational and Technology Management (ICACTM), London, UK, 24-26 April 2019. – IEEE, 2019. – P. 191–197.

260. Jose, J.T. Modeling of the magnetizing phenomena of doubly fed induction generator using neuro-fuzzy algorithm considering non-linearity / J.T. Jose, A.B. Chattopadhyay // *International Journal of Electrical and Computer Engineering*. – Vol. 9, Issue 1. – Institute of Advanced Engineering and Science, 2019. – P. 23–33.

261. Dawan, P. Comparison of Power Output Forecasting on the Photovoltaic System Using Adaptive Neuro-Fuzzy Inference Systems and Particle Swarm Optimization-Artificial Neural Network Model / P. Dawan, K. Sriprapha, S. Kittisontirak, T. Boonraksa, N. Junhuathon, W. Titiroongruang, S. Niemcharoen // *Energies*. – Vol.13, Issue 2. – MDPI, 2020. – P. 351–354.

262. Liu, Y. Smoothed L1/2 regularizer learning for split-complex valued neuro-fuzzy algorithm for TSK system and its convergence results / Y. Liu, D. Yang, F. Li // *Journal of the Franklin Institute*. – Vol. 355, Issue 13. – Elsevier, 2018. – P. 6132–6151.

263. Abdulshahed, A.M. The application of ANFIS prediction models for thermal error compensation on CNC machine tools / A.M. Abdulshahed, A.P. Longstaff, S. Fletcher // *Applied Soft Computing*. – 2015. – Vol. 27. – P. 158–168.

264. Spall, J. C. Introduction to Stochastic Search and Optimization / J. C. Spall. – Hoboken : Wiley, 2003. – 618 p.

265. Zhou, S. Fuzzy deep belief networks for semi-supervised sentiment classification / S. Zhou, Q. Chen, X. Wang // *Neurocomputing*. – 2014. – Vol. 131. – P. 312–322.

266. Aviles, A. A deep-neuro-fuzzy approach for estimating the interaction forces in robotic surgery / A. Aviles, S. Alsaleh, E. Montseny, P. Sobrevilla, A. Casals // *Fuzzy Systems : International Conference, Vancouver, 24-29 July 2016*. – IEEE, 2016. – P. 684–691.

267. Cantu-Paz, E. Efficient and accurate parallel genetic algorithms / E. Cantu-Paz. – Massachusetts: Kluwer Academic Publishers, 2001. – 162 p.

268. Yu, X. Introduction to Evolutionary Algorithms (Decision Engineering) / X. Yu, M. Gen. – London: Springer, 2010. – 418 p.

269. Abraham, A. Engineering Evolutionary Intelligent Systems / A. Abraham, C. Grosan, W. Pedrycz. – Berlin: Springer, 2008. – 444 p.

270. Пат. 70944 Україна, МПК G06F 19/24. Спосіб побудови дерев розв'язків для виявлення знань при діагностуванні виробів / Є. О. Гофман, А. О. Олійник, С. О. Субботін, (Україна); заявник Запорізький національний технічний університет. – № u2011 15678 ; заявл. 30.12.11 ; опубл. 25.06.12, Бюл. № 12.

271. Quinlan, J. R. Decision trees as probabilistic classifiers / J. R. Quinlan // Fourth International Workshop on Machine Learning. – Irvine : Morgan Kaufmann, 1987. – P. 31–37.

272. Quinlan, J. R. C.4.5: Programs for machine learning / J. R. Quinlan. – San Mateo : Morgan Kaufmann, 1993. – 312 p.

273. Safavian, S. R. A Survey of Decision Tree Classifier Methodology / S. R. Safavian, D. A. Landgrebe // IEEE Transactions on Systems, Man, and Cybernetics. – 1991. – № 21 (3). – P. 660–674.

274. Олійник, А. О. Видобування правил на основі дерев розв'язків та стохастичного пошуку / А. О. Олійник // Радіоелектроніка, інформатика, управління. – 2014. – № 2. – С. 110–119.

275. Гофман, Е. А. Эволюционный метод синтеза деревьев решений / Е. А. Гофман, А. А. Олейник, С. А. Субботин // Штучний інтелект. – 2011. – № 2. – С. 6–14.

276. Oliinyk, A. The decision tree construction based on a stochastic search for the neuro-fuzzy network synthesis / A. Oliinyk, S. A. Subbotin // Optical Memory and Neural Networks (Information Optics). – 2015. – Vol. 24, № 1. – P. 18–27.

277. Гофман, Е. А. Использование деревьев решений для диагностирования автотранспортных средств / Е. А. Гофман, А. А. Олейник, С. А. Субботин // Информационные управляющие системы и компьютерный мониторинг : II Всеукраинская научно-техническая конференция ИУС и КМ-

2011, Донецк, 11–13 апреля 2011 г. : материалы конференции. – Донецк : ДонНТУ, 2011. – Т. 1. – С. 159–163.

278. Гофман, Е. А. Применение деревьев решений для редукции баз лингвистических правил / Е. А. Гофман, А. А. Олейник, С.А Субботин // Информационные технологии и автоматизация–2011 : материалы Всеукраинской научно-производственной конференции, Одесса, 12–14 октября 2011 р. : тезисы докладов. – Одесса : ОНАПТ, 2011. – С. 11–12.

279. Олейник, А. А. Выявление латентных признаков в транзакционных базах данных / А. А. Олейник, Т. А. Зайко, С. А. Субботин // Информатика та комп'ютерні технології : IX міжнародна науково-технічна конференція, Донецьк, 4–6 листопада 2013 р. : матеріали конференції. – Донецьк : ДонНТУ, 2013. – С. 233–236.

280. Олійник, А. О. Редукція надлишкових екземплярів в транзакційних базах даних / А. О. Олійник, Т. А. Зайко, С. О. Субботін // Сучасні інформаційні системи та технології : III міжнародна науково-практична конференція AIST-2014, Суми, 14–16 травня 2014 р. : матеріали конференції. – Суми : СумДУ, 2014. – С. 97–98.

281. Олійник, А. О. Побудова асоціативних правил на основі інтелектуального стохастичного пошуку / А. О. Олійник // Математичні машини і системи. – 2015. – № 4. – С. 45–56.

282. Oliinyk, A. A stochastic approach for association rule extraction / A. Oliinyk, S. A. Subbotin // Pattern Recognition and Image Analysis. – 2016. – Vol. 26, № 2. – P. 419–426.

283. Subbotin, S. Diagnostic rule mining based on artificial immune system for a case of uneven distribution of classes in sample / S. Subbotin A. Oliinyk, V. Levashenko, E. Zaitseva // Communications – Scientific Letters of the University of Zilina. – 2016. – Vol. 3. – P. 4–12.

284. Олійник, А. О. Видобування продукційних правил на основі негативного відбору / А. О. Олійник // *Радіоелектроніка, інформатика, управління*. – 2016. – № 1. – С. 40–49.

285. Subbotin, S. Induction of classification rules in case of uneven distribution of classes / S. Subbotin, A. Oliinyk, V. Levashenko, E. Zaitseva // *Радіоелектронні і комп'ютерні системи*. – 2016. – №. 6 (80). – P. 176–180.

286. Oliinyk, A. O. Parallel Method of Production Rules Extraction Based on Computational Intelligence / A. Oliinyk, S. Skrupsky, S. Subbotin, I. Korobiichuk // *Automatic Control and Computer Sciences*. – 2017. – Vol. 51, Issue 4. – P. 215–223.

287. Олейник, А. А. Извлечение продукционных правил на основе гибридных методов вычислительного интеллекта / А. А. Олейник // *Сучасні проблеми і досягнення в галузі радіотехніки, телекомунікацій та інформаційних технологій : VIII міжнародна наукова-практична конференція, Запоріжжя, 21–23 вересня 2016 р. : матеріали конференції*. – Запоріжжя : ЗНТУ, 2016. – С. 324–325.

288. Oliinyk, A. O. Experimental research and analysis of complexity of parallel method for production rules extraction / A. Oliinyk, S. Skrupsky, S. Subbotin // *Automatic Control and Computer Sciences*. – 2018. – Vol. 52, Issue 2. – P. 89–99.

289. Oliinyk, A. A. The model for estimation of computer system used resources while extracting production rules based on parallel computations / A. A. Oliinyk, S. Yu. Skrupsky, V. V. Shkarupylo, S. A. Subbotin // *Радіоелектроніка, інформатика, управління*. – 2017. – № 1. – С. 142–152.

290. UCI Machine Learning Repository [Electronic resource]. – Access mode: <http://archive.ics.uci.edu/ml/>.

291. Subbotin, S.A. Synthesis of neuro-fuzzy models for the allocation and detection of objects on a complex background on the two-dimensional image / S.A. Subbotin // *Computer modeling and intelligent systems : proceedings of the conference*. – Zaporizhzhya: ZNTU, 2007. – P. 68–91.

292. Интеллектуальные информационные технологии проектирования автоматизированных систем диагностирования и распознавания образов : монография / С. А. Субботин, Ан. А. Олейник, Е. А. Гофман, С. А. Зайцев, Ал. А. Олейник ; под ред. С. А. Субботина. – Харьков : ООО “Компания Смит”, 2012. – 317 с.

293. Oliinyk, A. Training Sample Reduction Based on Association Rules for Neuro-Fuzzy Networks Synthesis / A. Oliinyk, T. Zaiko, S. Subbotin // Optical Memory and Neural Networks (Information Optics). – 2014. – Vol. 23, № 2. – P. 89–95.

294. Субботін, С. О. Ітеративні, еволюційні та мультиагентні методи синтезу нечіткологічних і нейромережних моделей: монографія / С. О. Субботін, А. О. Олійник, О. О. Олійник ; під заг. ред. С.О. Субботіна. – Запоріжжя : ЗНТУ, 2009. – 375 с.

295. Bonabeau, E. Swarm Intelligence: From Natural to Artificial Systems / E. Bonabeau, M. Dorigo, G. Theraulaz. – New York : Oxford University Press, 1999. – 320 p.

296. Олейник, А. А. Мультиагентный метод оптимизации с адаптивными параметрами / А. А. Олейник // Штучний інтелект. – 2011. – № 1. – С. 83–90.

297. Олійник, А. О. Мультиагентний метод з опосередкованим зв'язком між агентами / А. О. Олійник // Радіоелектроніка, інформатика, управління. – 2010. – № 2. – С. 82–89.

298. Олейник, А. А. Многомерный поиск на основе мультиагентного подхода / А. А. Олейник // Радиоэлектроника и информатика. – 2010. – № 2. – С. 51–55.

299. Haupt, R. Practical Genetic Algorithms / R. Haupt, S. Haupt. – New Jersey: John Wiley & Sons, 2004. – 261 p.

300. Soltoggio, A. Born to learn: The inspiration, progress, and future of evolved plastic artificial neural networks / A. Soltoggio, K. O. Stanley, S. Risi // *Neural Networks*. – 2018. – Vol. 108. – P. 48–67.

301. Shabash, B. EvoNN: a customizable evolutionary neural network with heterogenous activation functions / B. Shabash, K. Wiese // *The Genetic and Evolutionary Computation Conference Companion : A Recombination of the 27th International Conference on Genetic Algorithms (ICGA) and the 23rd Annual Genetic Programming Conference (GP), 15-19 July 2018 : proceedings*. – New York: ACM, 2018. – P. 1449–1456.

302. Baldominos, A. On the Automated, Evolutionary Design of Neural Networks-Past, Present, and Future / A. Baldominos, Y. Sáez, P. Isasi // *Neural Computing and Applications*. – 2019. – P. 1–45.

303. Baldominos, A. Evolutionary Design of Convolutional Neural Networks for Human Activity Recognition in Sensor-Rich Environments / A. Baldominos, Y. Sáez, P. Isasi // *Sensors*. – 2018. – Vol. 18, № 4. – P. 1–24.

304. Abraham, A. *Engineering Evolutionary Intelligent Systems* / A. Abraham, C. Grosan, W. Pedrycz. – Berlin: Springer, 2008. – 444 p.

305. Behjat, A. Adaptive Genomic Evolution of Neural Network Topologies (AGENT) for State-to-Action Mapping in Autonomous Agents / A. Behjat, S. Chidambaran, S. Chowdhury // *Conference on Robotics and Automation (ICRA' 2019) : IEEE International Conference, 20–24 May 2019 : proceedings*. – Montreal: IEEE, 2019. – P. 1–7.

306. Marzullo, A. A tensor-based mutation operator for Neuroevolution of Augmenting Topologies (NEAT) / A. Marzullo, C. Stamile, G. Terracina, F. Calimeri, S. Huffel // *IEEE Congress on Evolutionary Computation (CEC)*. – 2017. – P. 681–687.

307. Kadish, D. Clustering sensory inputs using NeuroEvolution of Augmenting Topologies / D. Kadish // *The Genetic and Evolutionary Computation Conference Companion : A Re-combination of the 27th International Conference on*

Genetic Algorithms (ICGA) and the 23rd Annual Genetic Programming Conference (GP), 15-19 July 2018 : proceedings. – New York: ACM, 2018. – P. 1–2.

308. Smith, S. Genetic and Evolutionary Computation: Medical Applications / S. Smith, S. Cagnoni. – Chichester: John Wiley & Sons, 2011. – 250 p.

309. Baragona, R. Evolutionary Statistical Procedures: An Evolutionary Computation Approach to Statistical Procedures Designs and Applications / R. Baragona, F. Battaglia, I. Poli. – Berlin: Springer, 2011. – 296 p.

310. Олейник, Ан. А. Агентные технологии для отбора информативных признаков / Ан. А. Олейник, Ал. А. Олейник, С. А. Субботин // Кибернетика и системный анализ. – 2012. – № 2. – С. 113–125.

311. Oliinyk, A. A. Parallel multiagent method of big data reduction for pattern recognition / A. A. Oliinyk, S. Yu. Skrupsky, V. V. Shkarupylo, O. Yu. Blagodariov // Радіоелектроніка, інформатика, управління. – 2017. – № 2. – С. 82–92.

312. Олійник, А. О. Редукція великих масивів даних на основі паралельного мультиагентного підходу / А. О. Олійник, С. О. Субботін // Тиждень науки : науково-практична конференція, Запоріжжя, 18–21 квітня 2017 р. : матеріали конференції. – Запоріжжя : ЗНТУ, 2017. – С. 701–703.

313. Oliinyk, A. The System of Criteria for Feature Informativeness Estimation in Pattern Recognition / A. Oliinyk, S. Subbotin, V. Lovkin, O. Blagodariov, T. Zaiko // Радіоелектроніка, інформатика, управління. – 2017. – № 4. – С. 85–96.

314. Oliinyk, A. Development of the indicator set of the features informativeness estimation for recognition and diagnostic model synthesis / A. Oliinyk, S. Subbotin, V. Lovkin, S. Leoshchenko, T. Zaiko // Advanced Trends in Radioelectronics, Telecommunications and Computer Engineering : 14th International Conference TCSET'2018, Lviv-Slavske, 20-24 February 2018 : Conference proceedings. – Lviv : Lviv Polytechnic National University, 2018. – P. 903–908.

315. Oliinyk, A. Parallel method of big data reduction based on stochastic programming approach / A. Oliinyk, S. Subbotin, V. Lovkin, M. Pyashenko, O. Blagodariov // *Радіоелектроніка, інформатика, управління.* – 2018. – № 2. – С. 60–72.

316. Oliinyk, A. A. Information Technology of Diagnosis Model Synthesis Based on Parallel Computing / A. A. Oliinyk, S. A. Subbotin, S. Yu. Skrupsky, V. M. Lovkin, T. A. Zaiko // *Радіоелектроніка, інформатика, управління.* – 2017. – № 3. – С. 139–151.

317. Методи та засоби оброблення великих даних в системах діагностування та розпізнавання образів : монографія / [С. О. Субботін, А. О. Олійник, В. М. Льовкін, Т. О. Колпакова, М. Ю. Пришляк, С. Ю. Леоценко, О.В. Корнієнко, Д.А. Каврін, Є.О. Гофман, О.Ю. Благодарьов] ; під заг. ред. С. О. Субботіна, А. О. Олійника. – Запоріжжя : ЗНТУ, 2018. – 228 с.

318. Oliinyk, A. Parallel data reduction method for complex technical objects and processes / A. Oliinyk, S. Leoshchenko, V. Lovkin, S. Subbotin, T. Zaiko // *Dependable Systems, Services and Technologies, (DESSERT'2018) : The 9th IEEE International Conference, Kyiv, 24-27 May, 2018 : proceedings.* – Los Alamitos: IEEE, 2018. – P. 496–501.

319. Oliinyk, A. Feature selection based on parallel stochastic computing / A. Oliinyk, S. Subbotin, V. Lovkin, S. Leoshchenko, T. Zaiko // *Computer Science and Information Technologies, (CSIT'2018) : XIII International Scientific and Technical Conference, Lviv, 11-14 September, 2018 : proceedings.* – Lviv: Vegha i Ko, 2018. – P. 347–351.

320. Олейник, А. А. Метод редукции данных для синтеза моделей неразрушающего контроля качества / А. А. Олейник, Т. А. Зайко, С. А. Субботин // *Информатика: проблемы, методология, технологии : XIV Международная конференция, Воронеж, 6–8 февраля 2014 г. : материалы конференции.* – Воронеж : Издательский дом Воронежского государственного университета, 2014. – Т. 3. – С. 140–144.

321. Oliinyk, A. O. Factor analysis of transaction data bases / A. O. Oliinyk, T. A. Zaiko, S. A. Subbotin // *Automatic Control and Computer Sciences*. – 2014. – Vol. 48, Issue 2. – P. 87–96.

322. Пат. 134493 Україна, МПК G06F 17/00. Спосіб відбору інформативних ознак великих даних для побудови розпізнавальних моделей / А. О. Олійник, В. М. Льовкін, (Україна); заявник Запорізький національний технічний університет. – № u2018 10874 ; заявл. 02.11.18 ; опубл. 27.05.19, Бюл. № 10/2019.

323. Олейник, А. А. Модель параметрического синтеза нейро-нечетких сетей в ярусно-параллельной форме / А. А. Олейник, С. Ю. Скрупский, С. А. Субботин // *Наукові праці Донецького національного технічного університету. Серія: "Інформатика, кібернетика та обчислювальна техніка"*. – 2014. – № 1 (19). – С. 106–113.

324. Олейник, А. А. Синтез диагностических и распознающих моделей на основе гибридных нейро-нечётких технологий вычислительного интеллекта : монография / А. А. Олейник, Т. А. Зайко, С. А. Субботин ; под ред. С. А. Субботина. – Харьков : ООО “Компания Смит”, 2014. – 284 с.

325. Oliinyk, A. O. Using Parallel Random Search to Train Fuzzy Neural Networks / A. O. Oliinyk, S. Yu. Skrupsky, S. A. Subbotin // *Automatic Control and Computer Sciences*. – 2014. – Vol. 48, Issue 6. – P. 313–323.

326. Oliinyk, A. A. Neural network synthesis based on evolutionary optimization / A. A. Oliinyk, S. A. Subbotin // *Системні дослідження та інформаційні технології*. – 2015. – № 1. – С. 77–86.

327. Олійник, А. О. Планування ресурсів паралельної обчислювальної системи при синтезі нейро-нечітких моделей для обробки великих даних / А. О. Олійник, С.Ю. Скрупський, С.О. Субботін, А.Ю. Благодарьов, Є.О. Гофман // *Радіоелектроніка, інформатика, управління*. – 2016. – № 4. – С. 61–69.

328. Гофман, Е. А. Синтез нейро-нечётких сетей на основе деревьев решений для диагностирования и автоматической классификации по признакам

/ Е. А. Гофман, С. А. Субботин, А. А. Олейник // *Радіоелектроніка та інформатика*. – 2012. – № 2. – С. 58–62.

329. Олейник, А. А. Синтез нейро-нечетких сетей на основе ассоциативных правил / А. А. Олейник, Т. А. Зайко, С. А. Субботин // *Кібернетика та системний аналіз*. – 2014. – Т. 50, № 3. – С. 27–38.

330. Олійник, А. О. Паралельний метод синтезу нейро-нечітких мереж / А. О. Олійник // *Тиждень науки : науково-практична конференція, Запоріжжя, 14–18 квітня 2014 р. : матеріали конференції*. – Запоріжжя : ЗНТУ, 2014. – Т. 2. – С. 128–130.

331. Гофман, Є. О. Метод структурно-параметричного синтезу нейро-фаззі мереж / Є. О. Гофман, А. О. Олійник, С. О. Субботін // *Сучасні інформаційні системи та технології : Міжнародна науково-практична конференція AIST–2012, Суми, 15–18 травня 2012 р. : матеріали конференції*. – Суми : СумДУ, 2012. – С. 175–176.

332. Oliinyk, A. O. Experimental Investigation with Analyzing the Training Method Complexity of Neuro-Fuzzy Networks Based on Parallel Random Search / A. O. Oliinyk, S. Yu. Skrupsky, S. A. Subbotin // *Automatic Control and Computer Sciences*. – 2015. – Vol. 49, Issue 1. – P. 11–20.

333. Oliinyk, A. Additional training of neuro-fuzzy diagnostic models / A. Oliinyk, S. Subbotin, S. Leoshchenko, M. Pyashenko, N. Myronova, Y. Mastinovskyy // *Радіоелектроніка, інформатика, управління*. – 2018. – № 3. – С. 106–119.

334. Олейник, А. А. Метод донавчання нейро-нечітких моделей / А. А. Олейник // *Сучасні проблеми і досягнення в галузі радіотехніки, телекомунікацій та інформаційних технологій : IX міжнародна науково-практична конференція, Запоріжжя, 03–05 жовтня 2018 р. : матеріали конференції*. – Запоріжжя : ЗНТУ, 2018. – С. 138–140.

335. Олійник, А. О. Дослідження процесу синтезу нейро-нечітких мереж на векторному процесорі / А. О. Олійник, С. Ю. Скрупський, С. О.

Субботін // Інформаційні управляючі системи та комп'ютерний моніторинг : V Всеукраїнська науково-технічна конференція ІУС КМ-2014, Донецьк, 22–23 квітня 2014 р. : матеріали конференції. – Донецьк : ДонНТУ, 2014. – Т. 1. – С. 371–375.

336. Subbotin, S. Individual prediction of the hypertensive patient condition based on computational intelligence / S. Subbotin, A. Oliinyk, S. Skrupsky // Information and Digital Technologies : International Conference IDT'2015, Zilina, 7–9 July 2015 : proceedings of the conference. – Zilina : Institute of Electrical and Electronics Engineers, 2015. – P. 336–344.

337. Олійник, А. О. Інтелектуальна інформаційна технологія параметричного синтезу нейро-фаззи мереж / А. О. Олійник, С. О. Субботін, С. Ю. Скрупський // Інформаційні технології : I Українська конференція молодих науковців ІТ–2014, Київ, 22–23 травня 2014 р. : матеріали конференції. – Київ : Інститут суспільства Київського університету імені Бориса Грінченка, 2014. – С. 126–128.

338. Олійник, А. О. Паралельний метод видобування продукційних правил / А. О. Олійник, О. Ю. Благодарьов // Комп'ютерні інтелектуальні системи та мережі : Всеукраїнська науково-практична конференція, Кривий Ріг, 21-23 березня 2018 р. : тези доповідей. – Кривий Ріг: Видавничий центр ДВНЗ «Криворізький національний університет», 2018. – С. 157–160.

339. Subbotin, S. The Fully-Defined Neuro-Fuzzy Model Synthesis / S. Subbotin, A. Oliinyk // Data Stream Mining & Processing (DSMP): 2016 IEEE First International Conference, Lviv, 23-27 August 2016 : proceedings. – Lviv: NU "Lvivska Politeckhnika", 2016. – P. 9–14.

340. Субботін, С. О. Згортальна нейронна мережа як парадигма для реалізації технології глибокого навчання / С. О. Субботін, А. О. Олійник, О. Ю. Благодарьов // Інформатика, управління та штучний інтелект : Науково-технічна конференція, Харків, 26–27 листопада 2014 р. : матеріали конференції. – Харків : НТУ «ХП», 2014. – С. 73.

341. Kolpakova, T. Improved method of group decision making in expert systems based on competitive agents selection / T. Kolpakova A. Oliinyk, V. Lovkin // 2017 IEEE First Ukraine Conference on Electrical and Computer Engineering (UKRCON), Kyiv, May 29 – June 2, 2017 : conference proceedings. – Kyiv: Institute of Electrical and Electronics Engineers, 2017. – P. 939–943.

342. Oliinyk, A. A. Evolutionary method for solving the traveling salesman problem / A. Oliinyk, I. Fedorchenko, A. Stepanenko, M. Rud, D. Goncharenko // Problems of Infocommunications. Science and Technology : 5th International Scientific-Practical Conference PICST2018, Kharkiv, 9–12 October 2018 : proceedings of the conference. – Kharkiv: Kharkiv National University of Radioelectronics, 2018. – P. 331–338.

343. Fedorchenko, I. Genetic method of image processing for motor vehicle recognition / I. Fedorchenko, A. Oliinyk, A. Stepanenko, T. Zaiko, A. Svyrydenko, D. Goncharenko [Electronic resource] // Proceedings of the Second International Workshop on Computer Modeling and Intelligent Systems (CMIS-2019), Zaporizhzhia, Ukraine, April 15-19, 2019. – P. 211-226. – (CEUR Workshop Proceedings, Vol. 2353). – Access mode: <http://ceur-ws.org/Vol-2353/paper17.pdf>.

344. Oliinyk, A. Development of Genetic Methods for Predicting the Incidence of Volumes of Emissions of Pollutants in Air / A. Oliinyk, I. Fedorchenko, A. Stepanenko, A. Katschan, Yu. Fedorchenko, A. Kharchenko, D. Goncharenko // Proceedings of the 2nd International Workshop on Informatics and Data-Driven Medicine IDDM 2019, Lviv, 11–13 November 2019 : proceedings of the workshop. – Lviv: Lviv Polytechnic National University, 2019. – P. 340–353. – (CEUR Workshop Proceedings, Vol. 2488).

345. Oliinyk, A. Combinatorial optimization problems solving based on evolutionary approach / A. Oliinyk, I. Fedorchenko, A. Stepanenko, M. Rud, D. Goncharenko // The experience of Designing and Application of CAD systems (CADSM): 15th International Conference CADSM'2019, Polyana (Svalyava), 26

February – 2 March 2019 : proceedings of the conference. – Lviv : Lviv Polytechnic National University, 2019. – P. 41–45.

346. Олійник, А. О. Синтез нейро-нечітких моделей для прогнозування стану здоров'я хворого на основі паралельних обчислень / А. О. Олійник // Радіоелектроніка, інформатика, управління. – 2015. – № 2. – С. 30–40.

347. Субботин, С. А. Применение аппарата деревьев решений в задаче диагностирования автомобильных кузовов / С. А. Субботин, Е. А. Гофман // Системний аналіз. Інформатика. Управління : II Всеукраїнська науково-практична конференція САІУ-2011, Запоріжжя, 10–11 березня 2011 р. : матеріали конференції. – Запоріжжя : КПУ, 2011. – С. 211–212.

348. Прогрессивные технологии моделирования, оптимизации и интеллектуальной автоматизации этапов жизненного цикла авиадвигателей : Монография / А. В. Богуслаев, Ал. А. Олейник, Ан. А. Олейник и др. ; под ред. Д. В. Павленко, С. А. Субботина. – Запорожье : ОАО «Мотор Сич», 2009. – 468 с.

349. Dubois, D. A systematic approach to the assessment of fuzzy association rules / D. Dubois, E. Hullermeier, H. Prade // Data Mining and Knowledge Discovery. – 2006. – Vol. 13. – P. 167–192.

350. Khan, M. S. Weighted association rule mining from binary and fuzzy data / M. S. Khan, M. Mueyba, F. Coenen // Lecture Notes in Computer Science. – 2008. – Vol. 5077. – P. 200–212.

351. Зайко, Т.А. Извлечение численных ассоциативных правил с учетом значимости признаков / Т. А. Зайко, А. А. Олейник, С. А. Субботин // Східно-Європейський журнал передових технологій. – 2013. – № 5/4 (65). – С. 28–34.

352. Субботин, С.А. Синтез нейро-нечетких моделей для выделения и распознавания объектов на сложном фоне по двумерному изображению / С. А. Субботин // Комп'ютерне моделювання та інтелектуальні системи : збірник наукових праць. – Запоріжжя: ЗНТУ, 2007. – С. 68–91.

ДОДАТОК А

Фрагменти вхідних даних та результати експериментальних досліджень

Таблиця А.1 – Фрагмент навчальної вибірки задачі неруйнівного контролю якості кузовів автотранспортних засобів [277, 292]

p_1	p_2	p_3	p_4	p_5	p_6	p_7	p_8	p_9	p_{10}	...	p_{48}	T
0,3	0,2	1,0	-0,6	-0,1	1,3	0,1	0,3	0,3	-0,3	...	0,2	1
1,0	-0,3	1,4	-0,3	-0,4	1,5	-0,1	0,0	0,3	-0,3	...	0,2	1
-0,3	-0,4	0,3	-0,1	-0,4	0,3	-0,8	0,1	-0,2	-1,0	...	-0,5	1
-1,4	-0,4	-0,1	-1,0	-0,1	0,4	-1,1	1,0	-0,4	-1,2	...	-0,8	1
-1,4	-0,2	-1,2	-1,0	0,2	-0,6	-0,9	0,2	-1,5	-1,0	...	-1,6	0
-0,7	-0,4	0,5	-0,9	0,0	0,5	-1,3	0,6	-0,2	-1,1	...	-0,4	1
-0,3	-0,5	-0,5	-0,5	0,0	-0,7	-0,7	0,1	-1,2	-1,1	...	-1,4	1
-0,4	-0,9	0,9	-0,8	-1,1	0,7	-0,8	-0,4	-0,3	-0,9	...	-0,9	1
-0,6	-0,2	-0,2	-0,5	-0,1	0,2	-1,2	0,4	-0,6	-1,4	...	-1,1	1
-1,2	-0,7	0,7	-1,7	-0,9	0,5	-1,3	-0,1	-0,6	-1,3	...	-1,0	1
-0,7	-0,1	0,4	-0,3	-0,6	0,1	-0,8	0,2	-0,7	-0,7	...	-0,7	1
-1,2	-0,3	-1,1	-0,8	-0,2	-0,8	-1,2	0,0	-1,3	-1,7	...	-2,0	0
-0,5	-0,2	1,3	-1,0	-0,5	0,3	-1,3	-0,3	-0,7	-1,4	...	-0,7	1
-1,0	-0,8	1,5	-1,8	-0,8	1,1	-1,7	-0,2	0,1	-1,9	...	-0,6	0
-0,9	-1,3	1,0	-1,5	-1,4	0,5	-1,4	-0,8	-0,1	-1,5	...	0,3	1
-0,9	-1,2	0,5	-1,3	-1,1	0,2	-2,1	-0,8	-0,2	-1,9	...	-0,9	1
-1,1	-0,5	0,8	-1,2	-0,9	0,8	-0,9	-0,5	0,1	-1,0	...	-0,8	1
-1,0	-0,3	0,4	-1,3	-0,4	0,7	-0,8	0,7	0,5	-1,0	...	-0,5	1
-0,2	-0,8	0,8	-0,6	-1,2	1,0	-0,9	0,4	0,2	-0,9	...	-0,1	0
0,3	-1,2	1,0	-0,3	-0,9	0,5	-1,0	-0,1	0,0	-0,8	...	0,3	0
-0,7	-0,7	1,2	-0,2	-1,3	1,8	-0,6	-0,4	0,8	-0,7	...	0,2	0
-1,2	-1,9	1,9	-1,2	-1,6	1,6	-0,8	-0,8	0,7	-0,3	...	1,1	0
...
1,1	-1,2	0,1	-0,5	-1,0	-0,3	0,1	0,1	-1,1	-0,2	...	-0,9	1

Таблиця А.2 – Фрагмент навчальної вибірки задачі виявлення прихованих залежностей між параметрами авіадвигунів при різних режимах випробувань [348]

P_1	P_2	P_3	P_4	P_5	P_6	P_7	P_8	P_9	P_{10}	P_{11}	P_{12}	P_{13}	P_{14}
97,7	886	465	18,4	98,8	1,8	2348	9,09	9,18	761,5	34,74	54,77	98,55	102,8
97,8	893	479	20	98,43	1,7	2205	8,92	8,79	752	34,62	54,41	98,4	103,57
97,95	–	478	–	97,01	2,4	2360	9,39	8,91	753	34,88	54,95	98,55	102,25
97,9	–	479	–	97,87	2,2	2283	9,2	9,14	760,5	34,64	54,65	98,3	102,85
97,7	897	472	14,3	98,16	1,6	2270	9,18	8,72	761	34,88	54,35	98,5	103,28
97,9	898	475	15,5	98,2	2,2	2305	9,29	8,9	755	34,82	54,53	98,35	102,5
97,95	979	470	16,5	97,29	1	2320	9,07	8,91	755	34,62	55,01	98,65	102,84
97,6	873	460	19,8	98	2,7	2321	9,32	8,92	751	–	–	–	–
97,8	903	472	16,1	98,3	1,9	2363	9,18	9,04	755	–	–	–	–
97,27	900	468	13,5	98,25	0,3	2360	9,14	9,06	753	–	–	–	–
98	899	476	12,3	97,6	1,9	2561	9,95	9,8	756	34,76	54,74	98,9	102,35
98,1	899	471	12,7	98,3	2,2	2305	9,02	8,94	756	34,68	54,71	98,8	102,54
98,1	891	–	13,8	98,9	3,1	2312	–	8,95	756	34,76	55,4	99,15	103,47
98,06	890	–	13,5	98,8	1,6	2274	–	8,85	754,5	34,9	54,38	98,85	101,79
97,92	880	–	11,6	97,98	0	2553	–	8,96	762	34,88	54,68	99,15	102,68
97,8	892	474	4,5	98,16	2,2	2304	9,2	8,96	756,5	34,62	54,95	99,25	102,19
98	904	474	8,1	97,79	–0,05	–	9,42	9,19	742,5	34,7	54,8	99,1	102,3
97,9	879	463	9,1	98	1,4	–	9,32	9,13	740	34,62	54,65	99,25	103,57
98	876	460	7,8	97,8	1,7	2435	9,5	9,48	740	34,8	54,53	98,75	102,88
–	872	465	7,1	98	1,4	2453	9,3	9,1	741	34,86	54,62	98,45	101,79
–	909	471	0,9	97,8	2,2	2354	9,14	8,96	750,5	34,86	55,49	99,2	102,63
–	885	466	17,4	97,9	2,4	2283	9,31	9,13	760	34,84	54,38	98,6	103,47
97,8	853	461	17,7	97,6	3	2301	9,4	9,07	758,5	34,84	54,38	98,6	103,47
97,5	905	475	17,3	97,75	2	2359	9,34	8,88	747	34,86	54,89	98,75	102,3
...
97,8	883	476	7	98,22	2,1	2320	9,22	9,13	754	34,88	54,59	98,35	103,57

Таблиця А.3 – Фрагмент навчальної вибірки задачі діагностування лопаток газотурбінних авіаційних двигунів [294, 348]

P_1	P_2	P_3	P_4	P_5	P_6	P_7	...	P_{80}	T
0,2924	0,1354	0,1337	0,9715	0,0218	0,5516	0,0166	...	0,0961	0
0,2828	0,1894	0,2973	0,6487	0,9223	0,5257	0,1191	...	0,3020	0
0,3852	0,4191	0,4002	0,0607	0,0630	0,1509	0,2024	...	0,0978	0
0,1563	0,0918	0,1783	0,3565	0,5814	0,4489	0,0282	...	0,3161	0
0,2034	0,2141	0,2275	0,8936	0,7235	0,9311	0,0396	...	0,2381	0
0,1876	0,1707	0,3844	0,9116	0,9645	0,8611	0,0243	...	0,3374	0
0,2227	0,2512	0,3009	0,9102	0,1571	0,5067	0,1553	...	0,8852	0
0,3057	0,1849	0,4943	0,6914	0,6520	0,7257	0,0898	...	0,7163	0
0,2523	0,0978	0,2741	0,3887	0,1948	0,7612	0,0494	...	0,1502	
0,1883	0,2967	0,3303	0,9048	0,6891	0,3253	0,1902	...	0,9984	0
...
0,1741	0,1351	0,3534	0,6104	0,1255	0,9963	0,1719	...	0,6503	0
0,0545	0,5344	0,2886	0,5912	0,9257	0,1647	0,0131	...	0,7172	1
0,0789	0,0488	0,1314	0,0223	0,4912	0,5354	0,0206	...	0,3291	1
0,0608	0,2518	0,1902	0,0367	0,7108	0,0670	0,0197	...	0,7829	1
0,0657	0,0934	0,1298	0,4976	0,8684	0,5799	0,0293	...	0,1254	1
0,0599	0,2248	0,0925	0,8341	0,6137	0,2671	0,0059	...	0,9302	1
0,0604	0,2673	0,1301	0,5982	0,0391	0,7019	0,0331	...	0,8573	1
...
0,0539	0,1038	0,1019	0,2068	0,1059	0,4139	0,0355	...	0,4041	1

Таблиця А.4 – Фрагмент навчальної вибірки задачі розпізнавання автотранспортних засобів за зображеннями [352]

P_1	P_2	P_3	P_4	P_5	P_6	P_7	...	P_{16384}	T
0,5500	0,3700	0,0164	0,0110	0,1490	0,1412	0,1412	...	0,1804	2
0,5567	0,3025	0,0109	0,0179	0,1804	0,1882	0,1961	...	0,1961	2
0,5200	0,3400	0,0233	0,0391	0,4235	0,4235	0,4314	...	0,2431	2
0,5700	0,3350	0,0174	0,0116	0,1412	0,1412	0,1412	...	0,1804	3
0,5467	0,3675	0,0105	0,0090	0,1412	0,1412	0,1412	...	0,1922	5
0,5300	0,3588	0,0430	0,0168	0,3020	0,2980	0,2980	...	0,3333	3
0,5567	0,3513	0,0698	0,0283	0,4235	0,4118	0,4157	...	0,4235	4
0,5067	0,3300	0,0190	0,0229	0,2902	0,2902	0,2902	...	0,4157	3
0,5667	0,3375	0,0326	0,0240	0,2824	0,2902	0,2902	...	0,4118	1
0,5033	0,2763	0,0318	0,0420	0,5255	0,5255	0,5216	...	0,7569	2
0,4633	0,3338	0,0195	0,0202	0,2667	0,2667	0,2745	...	0,3922	2
0,5300	0,2950	0,0211	0,0299	0,3725	0,3725	0,3647	...	0,3490	5
0,5700	0,3638	0,0336	0,0389	0,3922	0,4078	0,3922	...	0,3843	2
0,5667	0,3563	0,0926	0,0218	0,2588	0,2588	0,2510	...	0,3843	2
0,5900	0,3775	0,0721	0,0435	0,3059	0,2902	0,2980	...	0,1804	3
0,4933	0,2713	0,0748	0,0497	0,4980	0,4980	0,4980	...	0,1961	4
0,5100	0,3075	0,0238	0,0973	0,2824	0,2824	0,2745	...	0,2431	2
0,5500	0,3700	0,0164	0,0110	0,1490	0,1412	0,1412	...	0,1804	1
...
0,5333	0,4138	0,0660	0,0368	0,7137	0,7059	0,6980	...	0,6000	2

Таблиця А.5 – Фрагмент навчальної вибірки задачі розпізнавання легкових автомобілів [294, 352]

P_1	P_2	P_3	P_4	P_5	P_6	P_7	...	P_{26}	T
0,1804	0,1882	0,1882	0,1882	0,1743	0,1710	0,1823	...	0,1530	1
0,1961	0,1961	0,1961	0,1961	0,1644	0,1710	0,1554	...	0,1484	1
0,2431	0,2353	0,2275	0,3020	0,3670	0,3781	0,3948	...	0,3846	1
0,1804	0,1804	0,1882	0,1882	0,1627	0,1500	0,1444	...	0,1231	0
0,1725	0,1529	0,1765	0,2078	0,1726	0,1776	0,1720	...	0,1883	0
0,3373	0,3373	0,4549	0,4824	0,3595	0,3243	0,3421	...	0,3248	0
0,4118	0,4275	0,4078	0,4275	0,3758	0,3841	0,3467	...	0,4004	0
0,4157	0,4157	0,4235	0,4039	0,3536	0,3701	0,3393	...	0,3858	0
0,3137	0,4471	0,5373	0,4941	0,3617	0,3657	0,3564	...	0,3812	0
0,7373	0,7451	0,7412	0,7412	0,6217	0,6690	0,6053	...	0,6866	1
0,3882	0,3804	0,3843	0,3843	0,3270	0,3504	0,3352	...	0,3620	1
0,3608	0,3608	0,3608	0,3608	0,3379	0,3485	0,3425	...	0,3619	0
0,4000	0,4000	0,4078	0,4118	0,3676	0,3656	0,3770	...	0,3649	1
0,3843	0,4039	0,3843	0,3765	0,3275	0,3476	0,3292	...	0,3668	1
0,3843	0,3804	0,3765	0,3686	0,3725	0,3924	0,3675	...	0,3799	0
0,5961	0,6235	0,6039	0,6118	0,5516	0,5840	0,4672	...	0,6238	0
0,1961	0,1961	0,1961	0,1961	0,2775	0,2631	0,2599	...	0,2494	1
0,1961	0,1961	0,2039	0,2039	0,1816	0,1884	0,1895	...	0,1990	0
...
0,5882	0,5922	0,5529	0,5529	0,6278	0,6307	0,5310	...	0,6609	1

Таблиця А.6 – Фрагмент навчальної вибірки задачі діагностування деталей авіадвигунів [348]

P_1	P_2	P_3	P_4	P_5	P_6	P_7	...	P_{2610}	T
0,1638	0,2994	0,6048	0,1498	0,0697	0,1757	0,2338	...	0,1077	0
0,5696	0,6511	0,8352	0,5374	1,1297	0,3985	0,3683	...	0,1711	0
0,1491	0,1842	0,1138	0,1932	0,1387	0,0644	0,0521	...	0,0029	0
0,1881	0,2285	0,3048	0,2743	0,4622	0,2796	0,2537	...	0,0100	0
0,0600	0,1417	0,1172	0,4256	0,1842	0,1356	0,0940	...	0,0140	0
0,3494	0,3869	0,2649	1,2407	1,2630	0,3470	0,1330	...	0,0082	0
0,2610	0,2184	0,3506	0,8530	1,1143	0,3308	0,1705	...	0,0023	0
0,1947	0,4332	0,3096	0,6156	0,6971	0,5904	0,3567	...	0,0455	0
0,1563	0,1678	0,4287	0,3807	0,3396	0,3433	0,1871	...	0,0235	0
0,1375	0,3308	0,3321	0,6049	0,4041	0,0369	0,0383	...	0,0022	1
0,2710	0,4630	0,6936	1,3487	0,9261	0,2557	0,1680	...	0,0068	1
0,2220	0,4970	0,4554	1,0817	0,9237	0,2983	0,2737	...	0,0089	1
0,2428	0,4472	0,1999	0,1972	0,2640	0,1262	0,0991	...	0,0064	1
0,1616	0,2199	0,6978	0,3577	0,6169	0,1780	0,2204	...	0,0065	1
0,2972	0,2405	0,2279	0,4748	0,1942	0,0851	0,0711	...	0,0114	1
0,2085	0,5427	0,2268	0,5296	0,2492	0,0965	0,0633	...	0,0038	1
0,1488	0,1498	0,3289	0,7524	0,4174	0,1518	0,1284	...	0,0050	1
0,1363	0,1214	0,1497	0,3693	0,6330	0,3860	0,2992	...	0,0350	1
...
0,1713	0,1819	0,1077	0,1141	0,2722	0,1016	0,0475	...	0,0043	1

Таблиця А.7 – Фрагмент навчальної вибірки задачі побудови діагностичних моделей для прогнозування стану здоров'я хворих на артеріальну гіпертензію [336]

P_1	P_2	P_3	P_4	P_5	P_6	P_7	...	P_{24}	T
150	105	58	0	0	0	0	...	0	0
145	85	72	0	0	0	1	...	1	1
145	95	74	0	0	1	0	...	0	0
140	80	80	0	0	1	0	...	1	0
160	100	68	0	0	1	1	...	1	1
145	85	72	1	0	0	0	...	1	0
135	90	66	0	0	1	0	...	0	0
135	80	92	1	0	0	0	...	1	0
150	95	60	0	0	1	0	...	0	1
150	90	60	1	0	0	0	...	0	1
160	95	66	0	1	0	1	...	1	1
145	90	70	1	1	0	0	...	1	0
155	90	60	0	0	1	0	...	0	0
135	80	72	1	1	0	0	...	1	1
125	80	78	1	1	0	0	...	1	1
130	85	60	0	0	1	0	...	0	0
125	80	78	1	1	0	0	...	1	0
145	90	54	1	1	1	0	...	0	0
...
135	85	60	1	1	1	1		1	0




Рисунок А.1 – Усереднений час виконання методу ПМВПП на кластерах




Рисунок А.2 – Усереднений час виконання методу ПМВПП на графічних процесорах




Рисунок А.3 – Графік прискорення обчислювального процесу на кластерах




Рисунок А.4 – Графік прискорення обчислювального процесу на графічних процесорах




Рисунок А.5 – Графік зростання комунікаційних витрат обчислювального процесу методу ПМВПП від кількості задіяних ядер процесорів кластерів




Рисунок А.6 – Графік зростання комунікаційних витрат обчислювального процесу від кількості задіяних потоків GPU




Рисунок А.7 – Ефективність кластерів, що реалізують метод ПМВПП




Рисунок А.8 – Витрачений і прогнозований час виконання методу на кластері

($M=10240$; $Q=318$; $\alpha_{DT} = 0,2$; $\alpha_{AR} = 0,3$; $\alpha_{NS} = 0,5$)




Рисунок А.9 – Витрачений і прогнозований обсяг оперативної пам'яті при виконанні методу на кластері ($M=1023$; $Q=95$; $\alpha_{DT} = 0,2$; $\alpha_{AR} = 0,3$; $\alpha_{NS} = 0,5$)




Рисунок А.10 – Витрачений і прогнозований час виконання методу на GPU ($M=10240$; $Q=318$; $\alpha_{DT} = 0,15$; $\alpha_{AR} = 0,28$; $\alpha_{NS} = 0,57$)

Таблиця А.8 – Кількість виділених ознак у результаті застосування методів відбору ознак при розпізнаванні автотранспортних засобів

Метод відбору ознак	Значення критеріїв порівняння		
	k_{min}	k_{max}	k
Метод аналізу головних компонентів (МАГК) [59, 129]	12	13	12,4
Метод групового урахування аргументів (МГУА) [98, 131]	11	12	11,2
Канонічний метод еволюційного пошуку (КМЕП) [204–207, 294]	10	11	10,4
Метод почергового додавання і видалення ознак (МПДВО) [131, 132, 195]	11	13	12,2
Мультиагентний метод з непрямым зв'язком між агентами (ММНЗА) [294]	10	11	10,2
Мультиагентний метод з прямим зв'язком між агентами (ММПЗА) [294]	10	11	10,4
Паралельний метод редукції великих даних (ПМРВД)	10	11	10,2

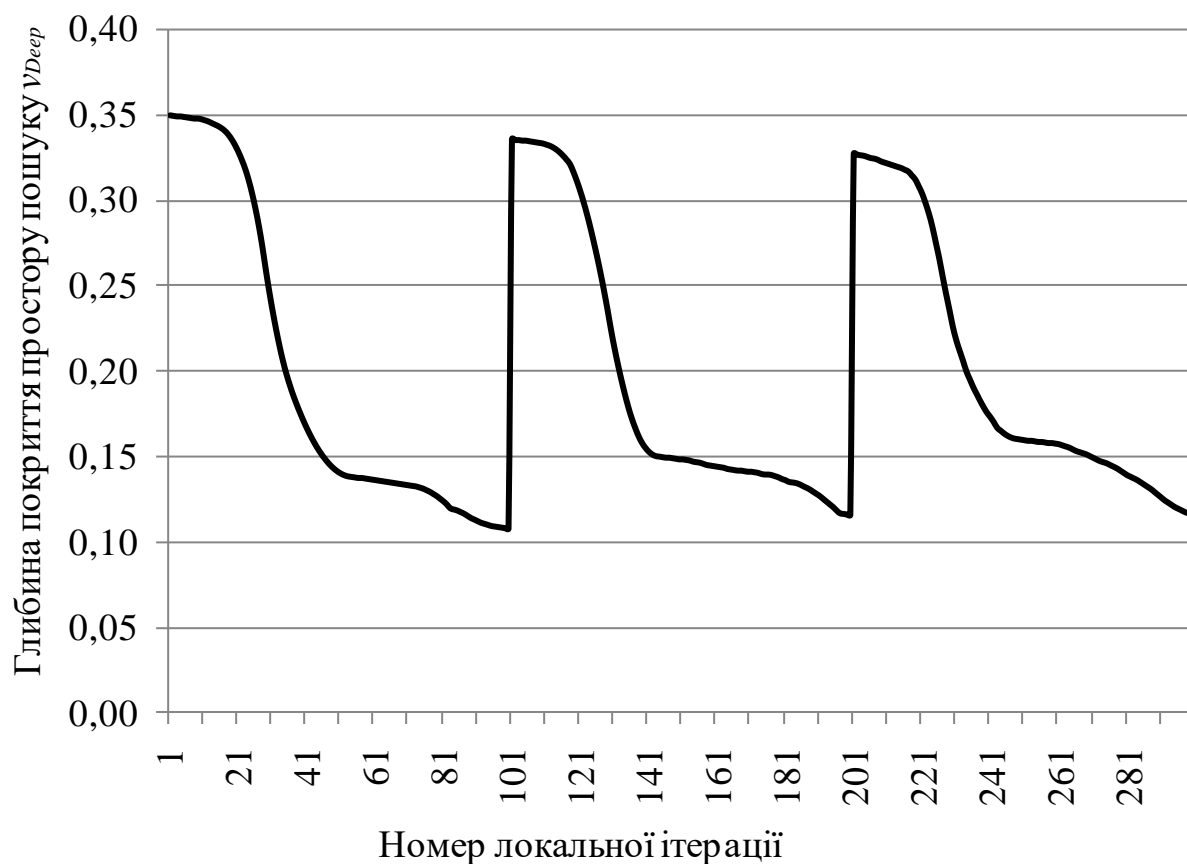


Рисунок А.11 – Графік залежності глибини покриття простору пошуку від номеру ітерації канонічного методу еволюційного пошуку




Рисунок А.12 – Графік залежності глибини покриття простору пошуку від номеру ітерації мультиагентного методу з прямим зв'язком між агентами

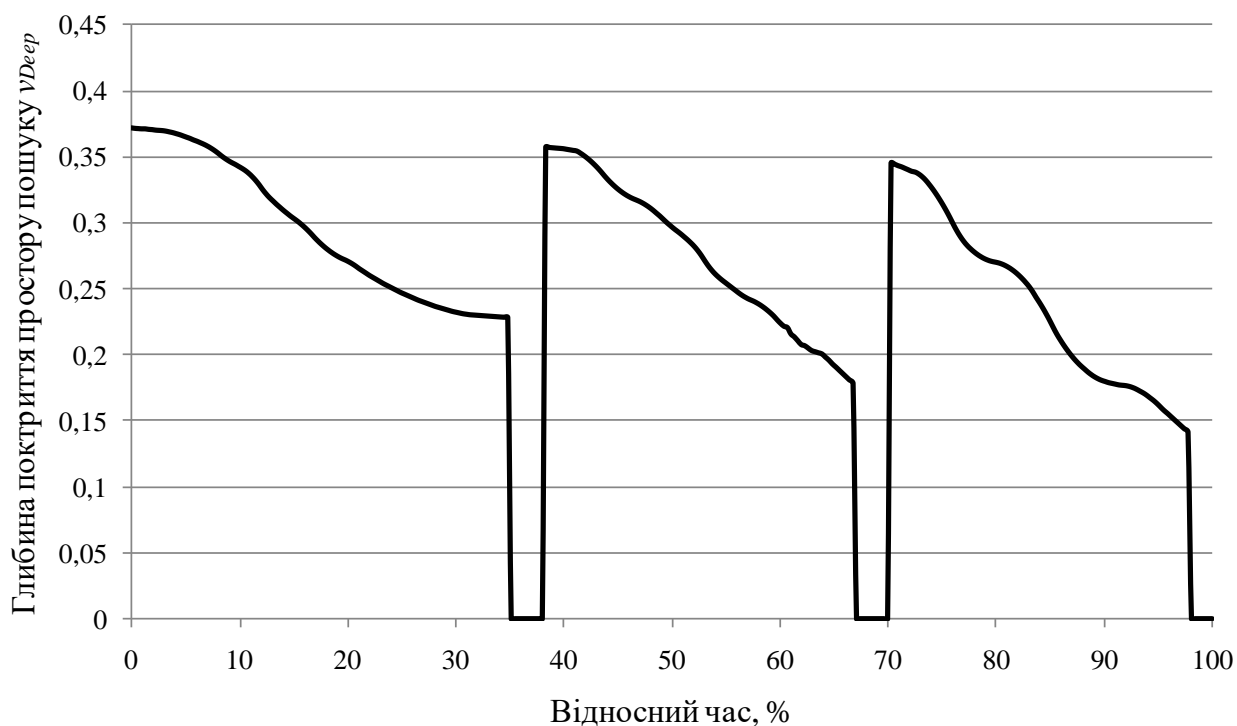


Рисунок А.13 – Графік залежності глибини покриття простору пошуку від номеру ітерації паралельного методу редукації великих даних

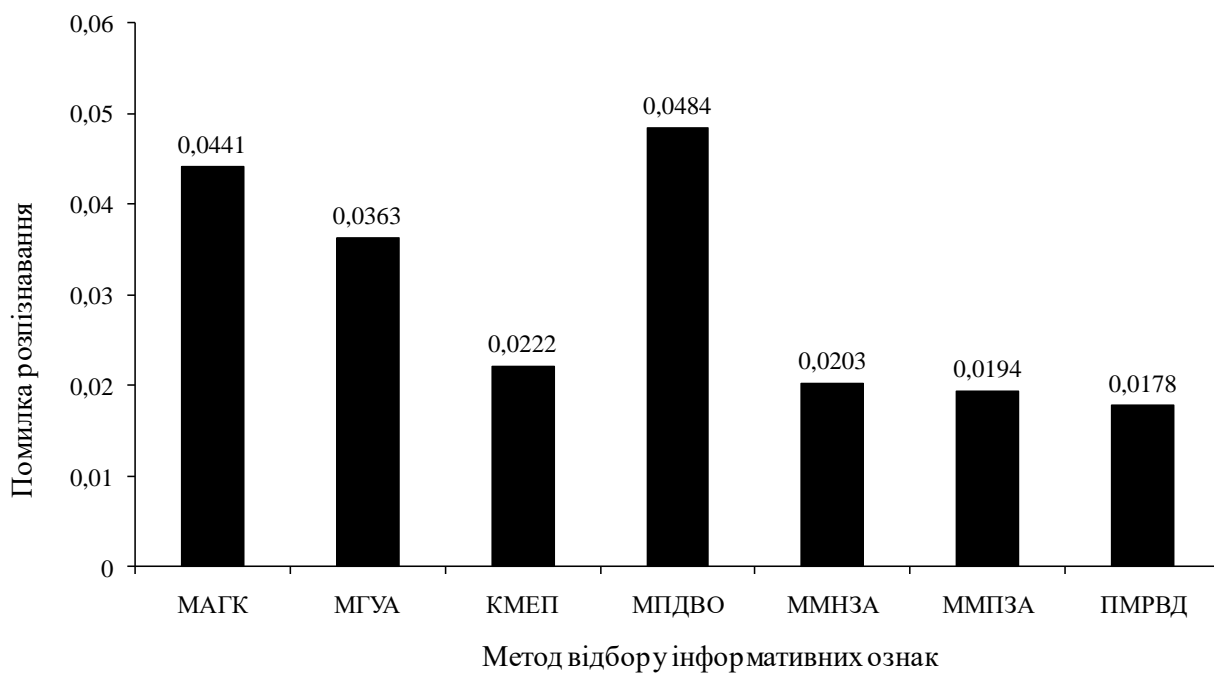


Рисунок А.14 – Діаграма розподілу рівня помилки розпізнавання автотранспортних засобів різними методами

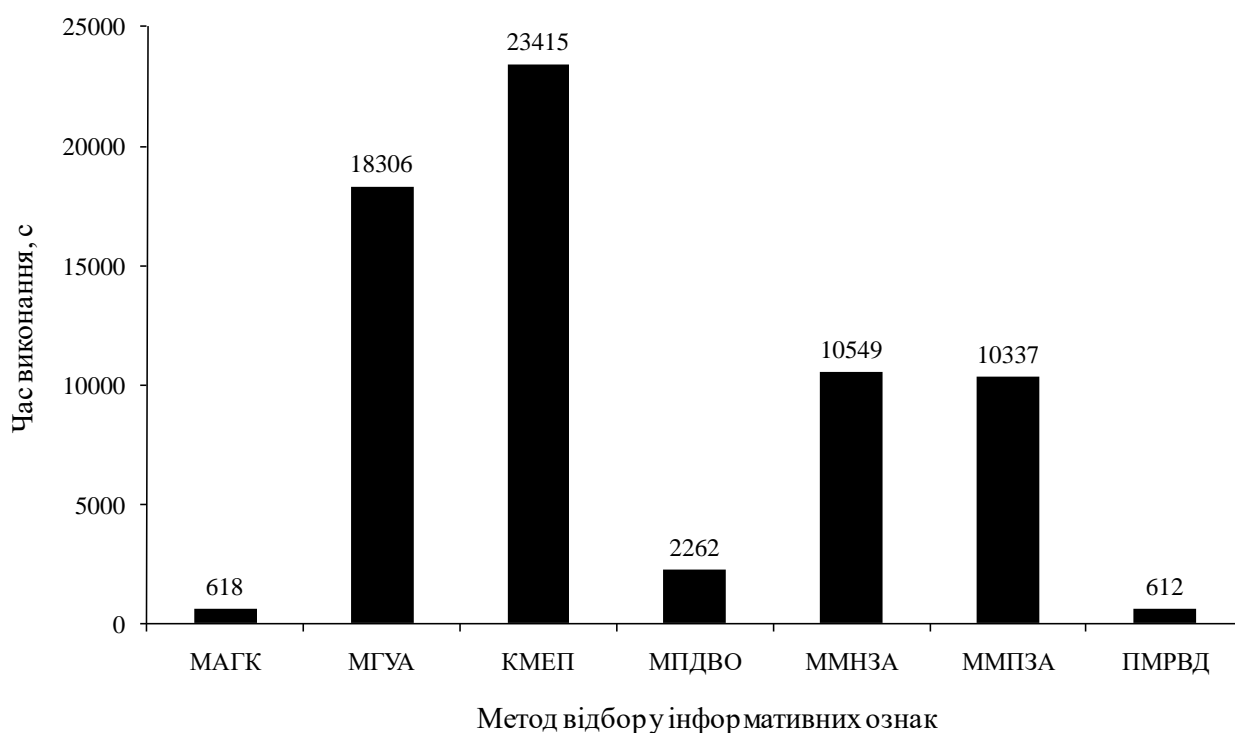


Рисунок А.15 – Діаграма розподілу часу виконання методів відбору ознак

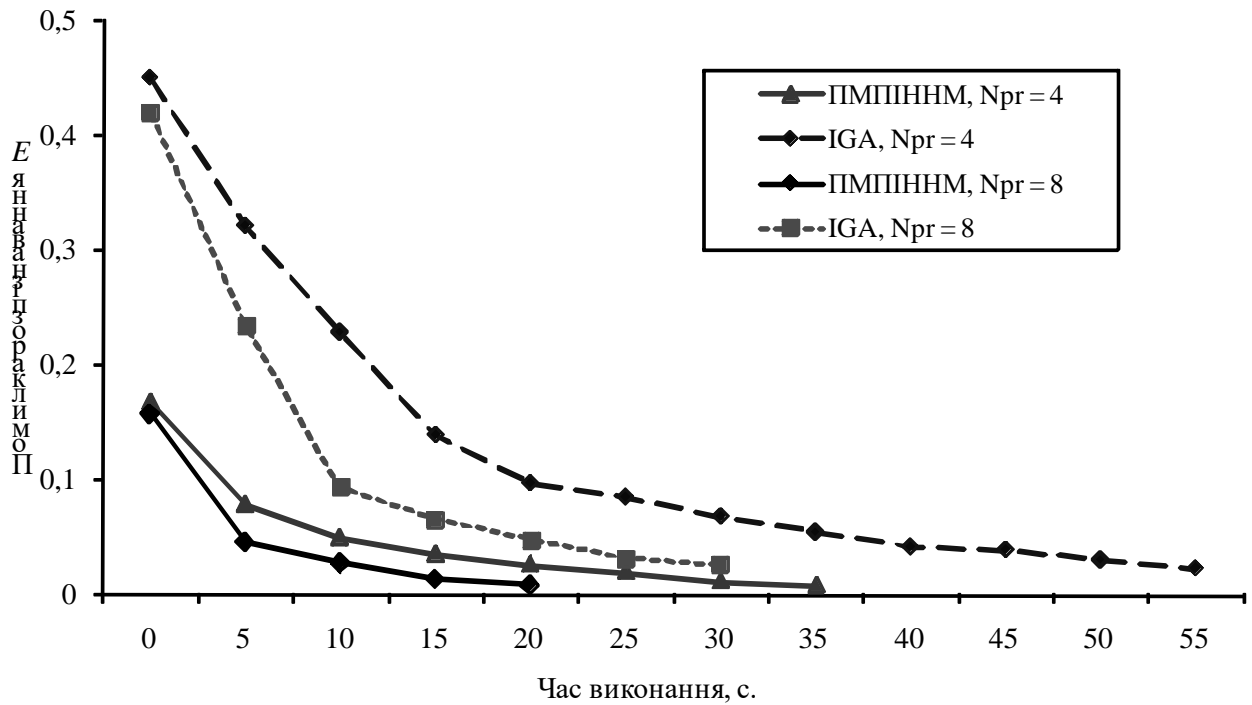


Рисунок А.16 – Графік залежності помилки розпізнавання E синтезованої нейро-нечіткої моделі від часу функціонування методів ПМПІННМ та IGA




Рисунок А.17 – Усереднені часові витрати на виконання методів ПМПІННМ та IGA у паралельній системі

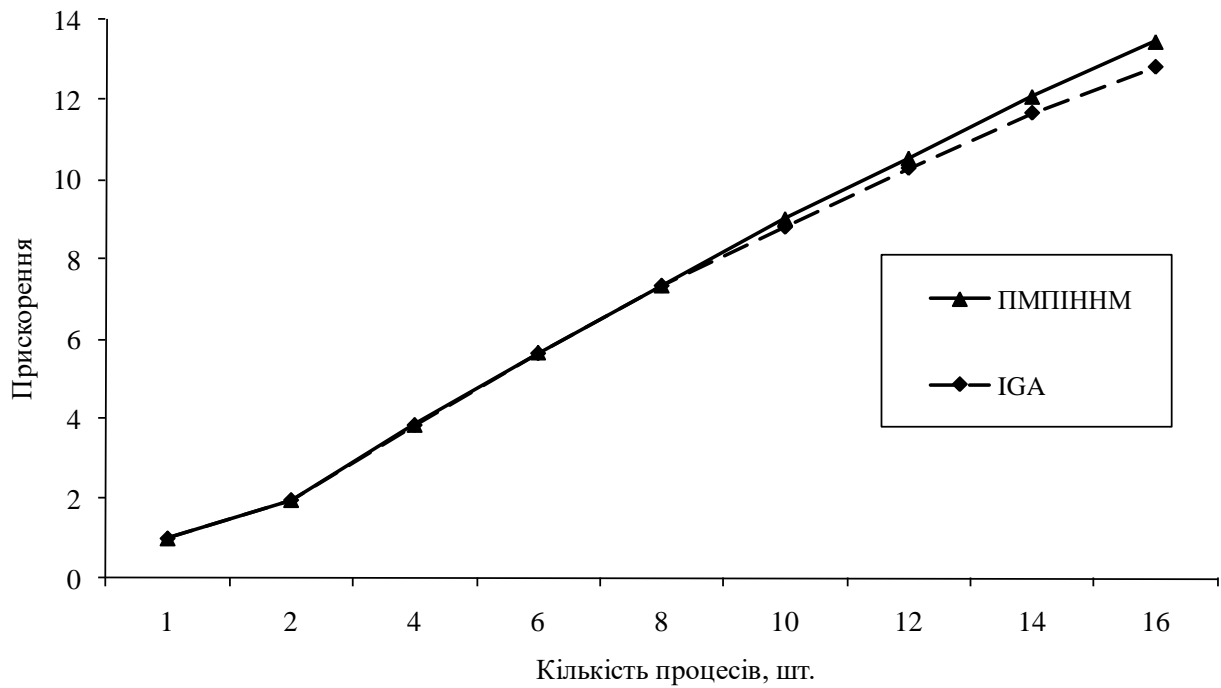


Рисунок А.18 – Графік прискорення параметричного синтезу нейро-нечітких мереж методами ПМПІННМ і IGA

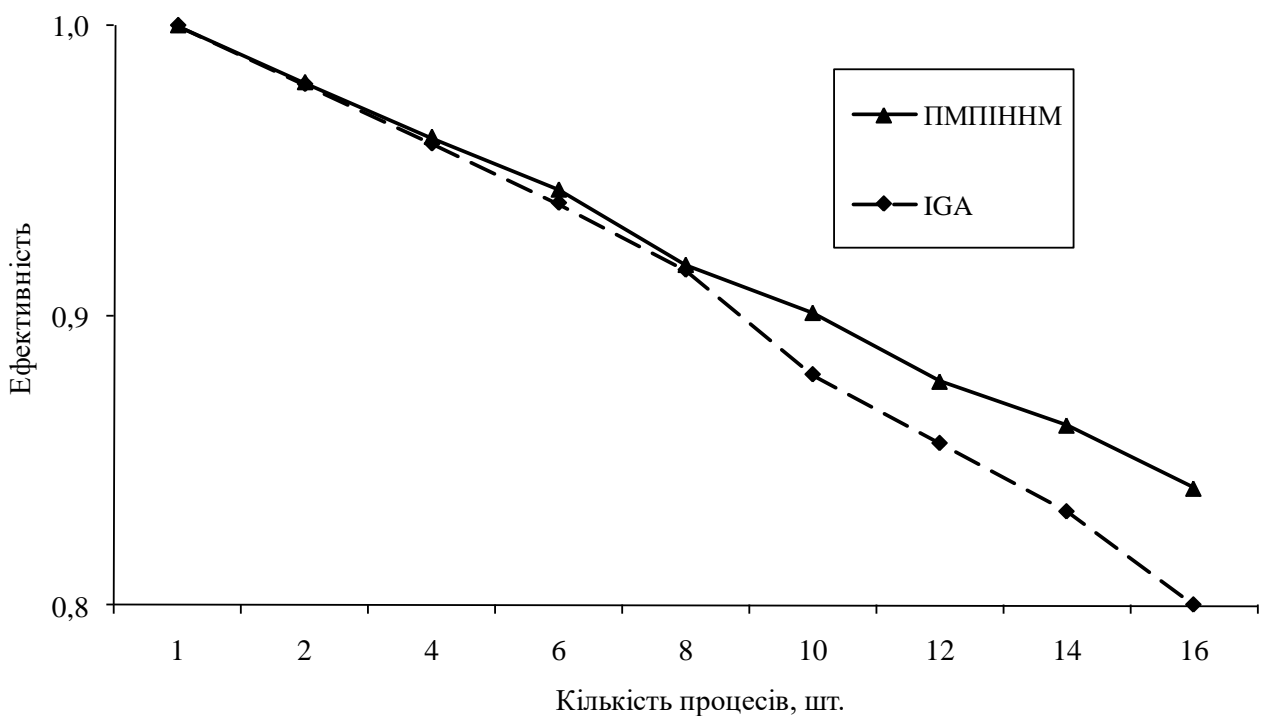


Рисунок А.19 – Графік ефективності паралельної системи, що виконує параметричний синтез нейро-нечітких мереж методами ПМПІННМ та IGA

Таблиця А.9 – Частка пересилань між процесами при різних частотах міграції L_{migr} та частках особин L_{Hmigr} , що мігрують

Кількість процесів, N_{pr}	Частка пересилань							
	$L_{migr} = 1/25$		$L_{migr} = 1/18$		$L_{migr} = 1/25$		$L_{migr} = 1/18$	
	$L_{Hmigr} = 2\%$		$L_{Hmigr} = 2\%$		$L_{Hmigr} = 5\%$		$L_{Hmigr} = 5\%$	
	ПМПІННМ	IGA	ПМПІННМ	IGA	ПМПІННМ	IGA	ПМПІННМ	IGA
1	0	0	0	0	0	0	0	0
2	0,02	0,018	0,024	0,020	0,022	0,02	0,026	0,023
4	0,04	0,037	0,049	0,041	0,046	0,041	0,054	0,049
6	0,06	0,051	0,076	0,059	0,07	0,057	0,086	0,069
8	0,09	0,072	0,115	0,082	0,108	0,082	0,133	0,1
10	0,11	0,100	0,143	0,11	0,134	0,117	0,167	0,143
12	0,14	0,123	0,185	0,124	0,174	0,146	0,218	0,18
14	0,16	0,142	0,216	0,190	0,202	0,172	0,258	0,213
16	0,19	0,176	0,264	0,183	0,244	0,216	0,319	0,271

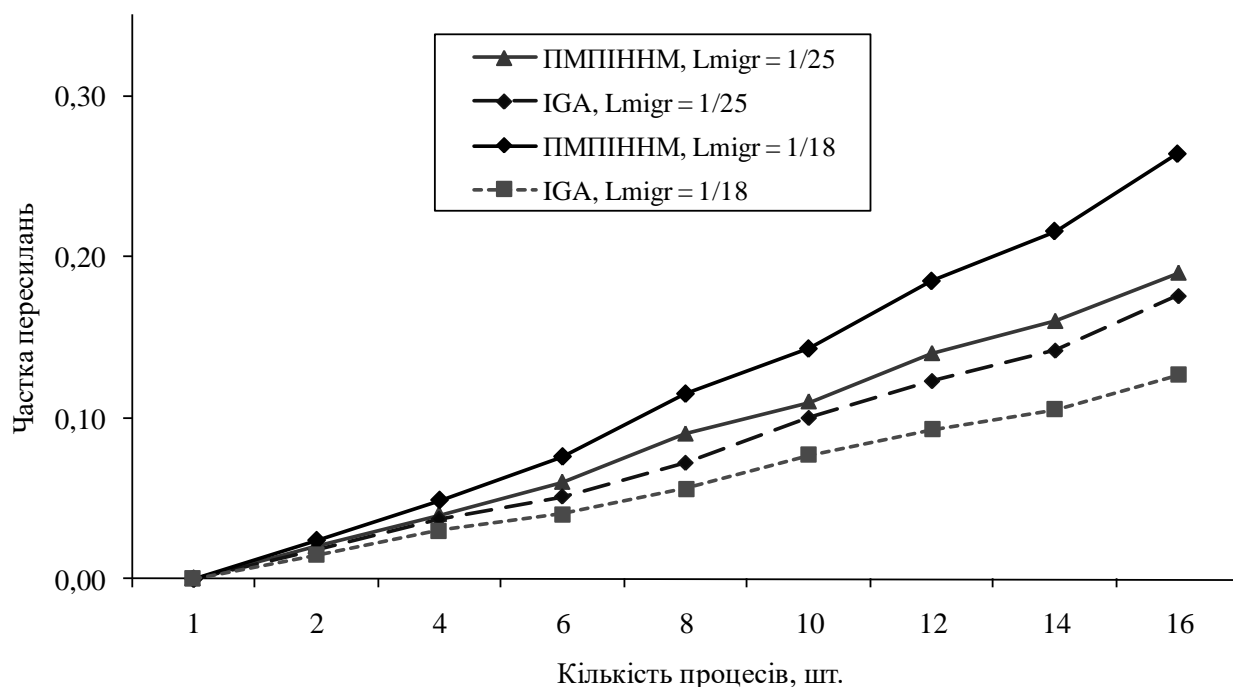


Рисунок А.20 – Залежність частки пересилань між процесами, що реалізують паралельні методи ПМПІННМ та IGA при різних частотах міграції L_{migr}

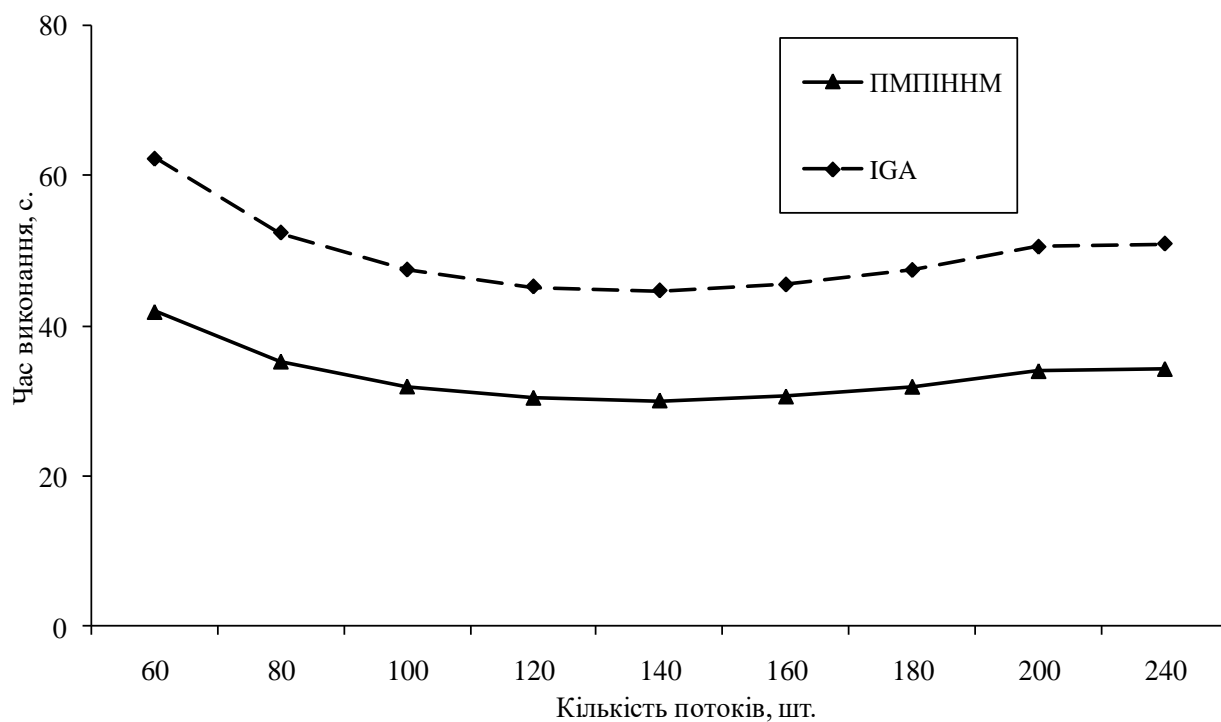


Рисунок А.21 – Усереднені часові витрати на виконання методу ПМПІННМ на векторному процесорі




Рисунок А.22 – Графік прискорення параметричного синтезу нейро-нечітких мереж запропонованим методом на GPU

Таблиця А.10 – Частка пересилань між процесами при різних частотах міграції L_{migr} та частках особин L_{Hmigr} , що мігрують

Кількість процесів, N_{pr}	Частка пересилань							
	$L_{migr} = 1/25$		$L_{migr} = 1/18$		$L_{migr} = 1/25$		$L_{migr} = 1/18$	
	$L_{Hmigr} = 2\%$		$L_{Hmigr} = 2\%$		$L_{Hmigr} = 5\%$		$L_{Hmigr} = 5\%$	
	ПМПІННМ	IGA	ПМПІННМ	IGA	ПМПІННМ	IGA	ПМПІННМ	IGA
60	0,112	0,117	0,119	0,129	0,113	0,11	0,119	0,11
80	0,122	0,132	0,144	0,162	0,140	0,13	0,145	0,14
100	0,132	0,144	0,160	0,179	0,156	0,15	0,160	0,16
120	0,143	0,158	0,176	0,203	0,172	0,17	0,177	0,17
140	0,153	0,172	0,193	0,226	0,188	0,18	0,194	0,19
160	0,163	0,187	0,209	0,239	0,204	0,20	0,209	0,2
180	0,173	0,205	0,223	0,259	0,218	0,21	0,224	0,22
200	0,184	0,224	0,239	0,281	0,234	0,23	0,248	0,25
240	0,210	0,247	0,275	0,312	0,269	0,26	0,276	0,27

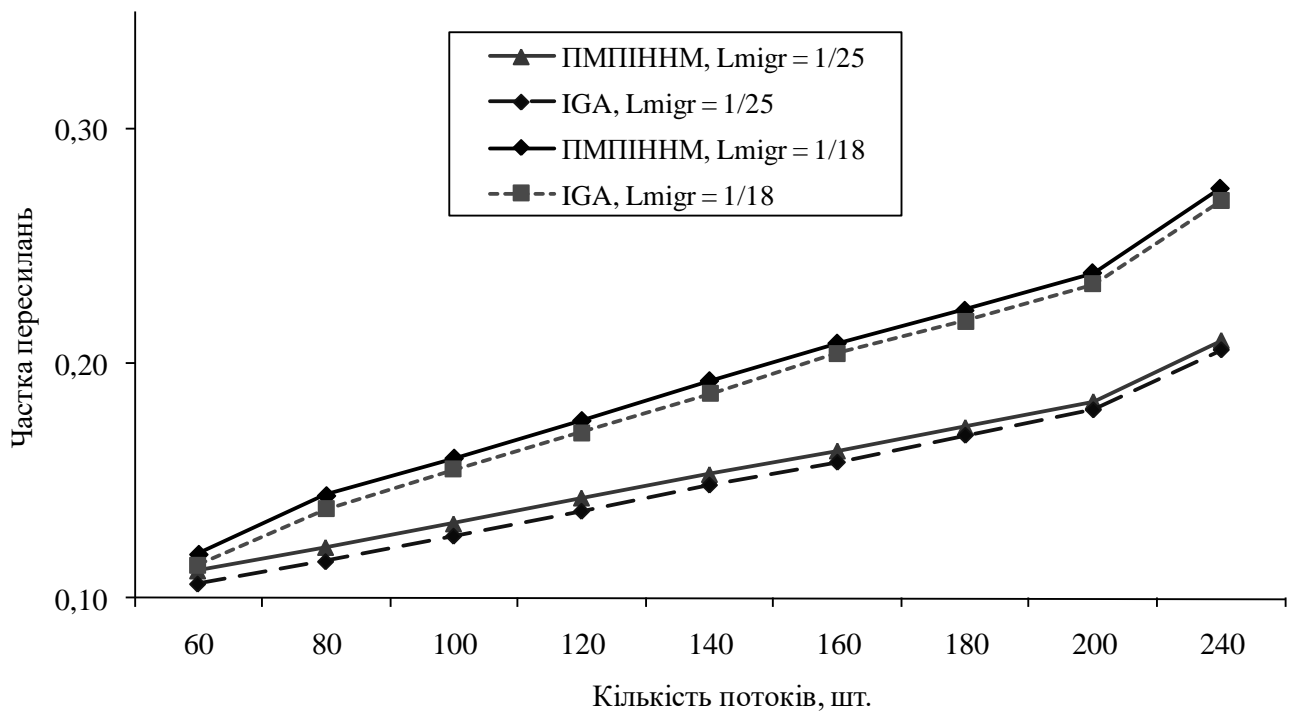



Рисунок А.23 – Залежність частки пересилань між потоками, що реалізують методи ПМПІННМ та IGA при частоті міграцій 1/25 та 2% мігруючих особин, від кількості потоків

ДОДАТОК Б

Акти впровадження дисертаційної роботи

ЗАТВЕРДЖУЮ

Головний конструктор



О.М. Дринов
ПІБ

« 27 » лютого 20 20 р.

АКТ

впровадження результатів докторської дисертації

Комісія в складі. Голова комісії: Головний конструктор тематичного напрямку, Дринов О.М. Члени комісії: Заступник Головного конструктора, начальник відділу перспективних розробок та газодинамічних розрахунків, Хусточка О.М., провідний інженер-конструктор тематичного напрямку Новіков О.М., цим актом засвідчує, що результати докторської дисертаційної роботи доцента кафедри програмних засобів Олійника Андрія Олександровича, виконаної у Національному університеті «Запорізька політехніка», впроваджено у виробництво Державного підприємства "Запорізьке машинобудівне конструкторське бюро "Прогрес" імені академіка О.Г.Івченка, де використовуються у науково-дослідній роботі, а також для автоматизації побудови діагностичних моделей.

Олійник А. О. розробив методи індукції діагностичних правил на основі паралельного комп'ютерного та обчислювального інтелекту, які дозволяють видобувати знання у вигляді продукційних правил з наявних вибірок даних про досліджувані об'єкти, що, в свою чергу, забезпечує можливість синтезу безнадлишкових та зручних для сприйняття й аналізу діагностичних моделей на основі вибірок даних великого об'єму. Запропоновані Олійником А.О. методи скорочення розмірності великих даних дозволяють виявляти неінформативні ознаки й екземпляри навчальної вибірки, що зменшує структурну і параметричну складність синтезованих діагностичних моделей, скорочує час їх синтезу, підвищує рівні узагальнення та інтепретовності моделей. Розроблений метод синтезу нейро-нечітких діагностичних моделей на основі паралельних обчислень на відміну від послідовних методів синтезу діагностичних моделей, які є застосовними лише для вузького класу об'єктів діагностування з добре вивченою природою, дозволяє будувати діагностичні моделі слабоформалізованих об'єктів та процесів,

передбачає паралельну реалізацію, що дозволяє в разі скоротити час синтезу моделей об'єктів діагностування.

Використання розробленого Олійником А.О. математичного забезпечення при розв'язанні завдань діагностування та управління якістю продукції дозволяє зменшити складність синтезованих діагностичних моделей та підвищити їх рівні узагальнення й інтепретовності у порівнянні з нейро-нечіткими моделями, побудованими шляхом безпосереднього відображення множини екземплярів у правила.

Підписи членів комісії:

Заступник Головного конструктора,
начальник відділу перспективних розробок
та газодинамічних розрахунків



О.М. Хусточка

Провідний інженер-конструктор



О.М. Новіков

ЗАТВЕРДЖУЮ
 Директор Лубенського
 верстатобудівного заводу
 Акціонерного товариства «Мотор Січ»



О.В. Луковка

ПБ

03 2020 р.

АКТ

впровадження результатів докторської дисертації
 Олійника Андрія Олександровича

Комісія у складі: головний технолог Федоренко Ю.Б., інженер відділу ВОТіЗ Марченко І.П. склала цей акт про те, що практичні результати, отримані доцентом Національного університету «Запорізька політехніка» Олійником Андрієм Олександровичем під час виконання ним докторської дисертації, впроваджено у виробництво Лубенського верстатобудівного заводу Акціонерного товариства "Мотор Січ", де використовуються у науково-дослідній роботі, а також для автоматизації побудови діагностичних та розпізнавальних моделей в інтелектуальних системах діагностування.

Олійник А. О. запропонував методи скорочення розмірності великих даних, які дозволяють виявляти неінформативні ознаки й екземпляри навчальної вибірки та виключати їх з подальшого розгляду при синтезі діагностичних моделей, що, у свою чергу, у порівнянні з відомими методами, зменшує структурну і параметричну складність отримуваних моделей, скорочує час їх синтезу, підвищує рівні узагальнення та інтерпретабельності діагностичних моделей, зменшує обсяг навчальної вибірки. Розроблені Олійником А. О. методи індукції діагностичних правил на основі паралельного комп'ютингу та обчислювального інтелекту (дерев розв'язків, асоціативних правил, негативного відбору) дозволять видобувати знання у вигляді продукційних правил з наявних вибірок даних про досліджувані об'єкти, що, в свою чергу, забезпечує можливість синтезу безнадлишкових та зручних для сприйняття й аналізу діагностичних моделей на основі вибірок даних великого

об'єму шляхом проекції набору видобутих нечітких продукційних правил у структуру нейро-нечіткої мережі. Розроблений паралельний метод синтезу нейро-нечітких діагностичних моделей на основі паралельного комп'ютингу на відміну від послідовних методів синтезу діагностичних моделей, які є застосовними лише для вузького класу об'єктів діагностування з добре вивченою природою, дозволяє будувати діагностичні моделі слабоформалізованих об'єктів та процесів, передбачає паралельну реалізацію, що дозволяє в разі скоротити час синтезу моделей об'єктів діагностування.

Розроблені методи обробки даних для діагностування на основі обчислювального інтелекту використовуються для синтезу розпізнавальних і діагностичних моделей для їх подальшого застосування при вирішенні задач діагностування деталей технічних виробів.

Цей акт не є підставою для фінансових розрахунків.

Головний технолог



Ю.Б. Федоренко

Інженер відділу ВОТіЗ



І.П. Марченко

ЗАТВЕРДЖУЮ
Начальник управління
корпоративних інтегрованих
систем ПАТ «Запоріжсталь»

У.В. Погумях
"28" _____ 2020 р.
Управління
корпоративних
інтегрованих
систем
комбінат «Запоріжсталь»

АКТ ВПРОВАДЖЕННЯ

1. Метод параметричної ідентифікації нейро-нечітких мереж на основі паралельного стохастичного пошуку. Метод модифікації діагностичних нейро-нечітких моделей

(назва пропозиції для впровадження)

2. Національний університет «Запорізька політехніка», вул. Жуковського, 64, м. Запоріжжя, 69118, Україна, автор – Олійник Андрій Олександрович, кандидат технічних наук, доцент, доцент кафедри програмних засобів

(установа-розробник, її поштова адреса, П.І.Б. авторів)

3. Джерело інформації:

3.1 Oliinyk A. O. Using Parallel Random Search to Train Fuzzy Neural Networks / A. O. Oliinyk, S. Yu. Skrupsky, S. A. Subbotin // Automatic Control and Computer Sciences. – 2014. – Vol. 48, Issue 6. – P. 313–323.

3.2 Oliinyk A. Additional training of neuro-fuzzy diagnostic models / A. Oliinyk, S. Subbotin, S. Leoshchenko, M. Ilyashenko, N. Myronova, Y. Mastinovsky // Радіоелектроніка, інформатика, управління. – 2018. – № 3. – С. 106–119.

4. Впроваджено за 2018-2019 рр. на Публічному акціонерному товаристві «Запорізький металургійний комбінат «Запоріжсталь»

(назва установи)

5. Перспективність впровадження. Розроблений метод синтезу нейро-нечітких мереж дозволяє створювати моделі для діагностування технічних об'єктів. Запропонований метод донавчання нейро-нечітких мереж дозволяє модифікувати існуючі діагностичні моделі шляхом з урахуванням інформації, отриманої в результаті нових спостережень за об'єктом діагностування. Застосування запропонованих методів дозволило суттєво підвищити швидкість побудови діагностичних моделей, а також збільшити їх точність та узагальнення даних.

Цей акт не є підставою для фінансових розрахунків.

«28» січня _____ 2020 р.

Відповідальні за впровадження:

/ Начальник відділу

Провідний інженер

В.М. Пихтєєв
Л.М. Путілова

В.М. Пихтєєв

Л.М. Путілова

ЗАТВЕРДЖУЮ
 Директор
 ТОВ "Софт Х"
 О. Ю. Бутко
 2019р.



АКТ

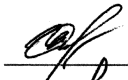
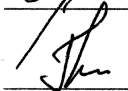

впровадження результатів докторської дисертації

Ми, що нижче підписалися, комісія у складі: начальника юридичного відділу Іваненка В.В., головного інженера Гарковенка А.О., завідувача лабораторією Набойченка І.В., склали цей акт про те, що практичні результати, отримані доцентом Національного університету «Запорізька політехніка» Олійником Андрієм Олександровичем під час виконання ним докторської дисертації, впроваджено у виробництво Товариства з обмеженою відповідальністю "Софт Х", де використовуються у науково-дослідній роботі, а також для автоматизації побудови діагностичних моделей в інтелектуальних системах діагностування.

Олійник А. О. запропонував методи видобування діагностичних правил на основі паралельного комп'ютингу та обчислювального інтелекту (дерев розв'язків, асоціативних правил, негативного відбору), а також методи скорочення розмірності великих даних, що дозволяють виявляти інформативні ознаки та екземпляри з навчальних вибірок даних великого обсягу та будувати на їх основі діагностичні моделі з високими рівнями узагальнення та інтепретовності у порівнянні з моделями, синтезованими на основі відомих методів. Розроблений Олійником А.О. паралельний метод синтезу нейро-нечітких діагностичних моделей на відміну від послідовних методів побудови діагностичних моделей, які є застосовними лише для вузького класу об'єктів діагностування з добре вивченою природою, дозволяє будувати діагностичні моделі слабоформалізованих об'єктів та процесів, передбачає паралельну реалізацію, що дозволяє в разі скоротити час синтезу моделей об'єктів діагностування.

Запропоновані Олійником А. О. методи дозволяють автоматизувати процес побудови діагностичних моделей в інтелектуальних системах. Синтезовані за допомогою розроблених методів діагностичні моделі характеризуються більш високим рівнем узагальнення в порівнянні з моделями, побудованими шляхом відображення заданого набору екземплярів у правила.

Розроблені Олійником А. О. методи синтезу діагностичних моделей на основі інтелектуальних обчислень для неруйнівного діагностування використовуються для синтезу розпізнавальних і діагностичних моделей для їх подальшого застосування при вирішенні задач технічного діагностування.

Начальник юридичного відділу		В. В. Іваненко
Головний інженер		А. О. Гарковенко
Завідувач лабораторією		І. В. Набойченко

АКТ
впровадження результатів докторської дисертації
Олійника Андрія Олександровича

Комісія у складі:

Голова: директор товариства з обмеженою відповідальністю «Науково-виробниче підприємство «Енергоальянс» О. В. Антонюк

Члени комісії: начальник відділу технічного обслуговування та діагностування електричного устаткування (ТОДЕУ) Р. В. Лавренко,
інженер відділу ТОДЕУ О. Д. Резніков

склала цей акт про те, що наукові та практичні результати, отримані доцентом Запорізького національного технічного університету Олійником Андрієм Олександровичем під час виконання ним докторської дисертації, впроваджено у практичну діяльність товариства з обмеженою відповідальністю «Науково-виробниче підприємство «Енергоальянс», де використовуються для побудови діагностичних моделей при розв'язанні практичних завдань технічного обслуговування та діагностування устаткування.

Комісія підтверджує працездатність розроблених Олійником А.О. методів видобування діагностичних правил на основі паралельного комп'ютингу та обчислювального інтелекту (дерев розв'язків, асоціативних правил, негативного відбору), а також методів скорочення розмірності великих даних. Результати апробації та впровадження підтверджують, що розроблені методи дозволяють виявляти інформативні ознаки та екземпляри з навчальних вибірок даних великого обсягу та синтезувати на їх основі діагностичні моделі з високими рівнями узагальнення та інтепретовності у порівнянні з моделями, синтезованими на основі відомих методів. За результатами використання запропонованих Олійником А. О. методів виявлено, що синтезовані за допомогою розроблених методів діагностичні моделі характеризуються більш високими рівнями узагальнення та інтепретовності в порівнянні з моделями, побудованими шляхом відображення заданого набору екземплярів у правила.

«14» 04 2016 р.

Директор ТОВ «Науково-виробниче підприємство «Енергоальянс»

Начальник відділу ТОДЕУ


Інженер відділу ТОДЕУ



О. В. Антонюк

Р. В. Лавренко

О. Д. Резніков



АКТ

впровадження результатів докторської дисертації А. О. Олійника

Ми, що нижче підписалися, комісія у складі: зав.виробництвом І.Н. Теплової, начальника юридичного відділу В.В.Чернова, головного бухгалтера Н.О. П'ятирик, склали цей акт про те, що результати, отримані доцентом Національного університету «Запорізька політехніка» Олійником Андрієм Олександровичем під час виконання ним докторської дисертації під керівництвом д.т.н., професора С. О. Субботіна, впроваджено у виробництво та науково-дослідну роботу ТОВ "Дніпро-Трейд", де використовуються для вирішення завдань автоматизації діагностування та контролю якості продукції.

Олійник А.О. створив нові методи скорочення розмірності великих даних для спрощення процесу побудови інтелектуальних моделей. Запропоновані Олійником А.О. методи скорочення розмірності великих даних дозволяють виявляти неінформативні ознаки й екземпляри навчальної вибірки, що зменшують структурну і параметричну складність синтезованих діагностичних моделей, скорочує час їх синтезу, підвищує рівні узагальнення та інтепретовності моделей. Олійник А. О. розробив методи індукції діагностичних правил на основі паралельного комп'ютерного та обчислювального інтелекту, а також метод синтезу нейро-нечітких діагностичних моделей на основі паралельних обчислень, який, на відміну від послідовних методів синтезу діагностичних моделей, дозволяє будувати діагностичні моделі слабоформалізованих об'єктів та процесів, передбачає паралельну реалізацію, що дозволяє суттєво (в рази) скоротити час синтезу моделей об'єктів діагностування.

За допомогою розроблених методів вирішено практичні задачі синтезу діагностичних моделей якості кондитерської продукції, зокрема виявлено набір інформативних ознак та екземплярів і побудовано нейро-нечітку діагностичну модель якості кондитерської продукції, що узагальнює інформацію, яка подана у вигляді масиву даних і містить відомості про характеристики використовуваної сировини, її параметри, а також параметри устаткування та техпроцесів; забезпечено можливість оцінювання характеристик сировини шляхом застосування синтезованої моделі, що дозволяє перевіряти якість сировини, одержуваної від окремих постачальників.

Зав.виробництвом


І.Н. Теплова

Начальник юридичного відділу

В.В.Чернов

Головний бухгалтер

Н.О. П'ятирик



АКТ

впровадження результатів докторської дисертації

Ми, що нижче підписалися, комісія у складі проректора з науково-педагогічної роботи та питань перспектив розвитку університету, директора Інституту інформатики та радіоелектроніки, доктора технічних наук, професора Д. М. Пізи, завідувача кафедри програмних засобів, доктора технічних наук, професора С. О. Субботіна, професора кафедри програмних засобів, кандидата технічних наук, професора В. І. Дубровіна, склали цей акт про те, що результати, отримані доцентом кафедри програмних засобів Національного університету «Запорізька політехніка» (НУ «Запорізька політехніка») Андрієм Олександровичем Олійником під час виконання ним докторської дисертації, впроваджено на кафедрі програмних засобів Інституту інформатики та радіоелектроніки НУ «Запорізька політехніка», де вони використовуються у навчальному процесі та науково-дослідній роботі.

Дисертаційна робота Олійника А.О. виконувалася в межах шістьох держбюджетних науково-дослідних робіт НУ «Запорізька політехніка»: «Інтелектуальні інформаційні технології автоматизації проектування, моделювання, керування та діагностування виробничих процесів і систем» (№ держ. реєстрації – 0112U005350), «Інтелектуальні інформаційні технології діагностування та автоматичної класифікації» (№ держ. реєстрації – 0115U004676), «Методи і засоби обчислювального інтелекту та паралельного комп'ютингу для оброблення великих даних в системах діагностування» (№ держ. реєстрації – 0116U007419), «Методи і засоби прийняття рішень для оброблення даних в інтелектуальних системах розпізнавання образів» (№ держ. реєстрації – 0117U003920), «Інтелектуальні інформаційні технології обробки даних» (№ держ. реєстрації – 0118U100063), «Інтелектуальні методи та програмні засоби діагностування й неруйнівного контролю якості техніки військового та цивільного призначення» (№ держ. реєстрації – 0119U100360).

Олійник А.О. розробив та дослідив нові методи обробки даних та побудови діагностичних моделей на основі нейро-нечітких мереж. Ним розроблено методи видобування продукційних правил на основі дерев розв'язків, чисельних асоціативних правил та негативного відбору, що дозволяють скоротити часові витрати на синтез моделей при розв'язанні складних практичних задач, які характеризуються великими обсягами діагностичних даних. Набула подальшого розвитку система критеріїв оцінювання інформативності ознак, запропоновано паралельний стохастичний метод

редукції даних, що передбачає використання різних стратегій стохастичного пошуку, які реалізуються на різних вузлах паралельної системи, що дозволяє розширити покриття простору пошуку. Олійником А.О. запропоновано метод параметричної ідентифікації нейро-нечітких мереж на основі паралельного випадкового пошуку, що для настроювання параметрів синтезованих моделей (параметри функцій належності та вагові коефіцієнти нейроелементів) використовує ймовірнісну оптимізацію, початкову множину рішень формує з урахуванням інформації про навчальну вибірку (враховується значущість термів ознак, використовуючи щільність розташування екземплярів навчальної множини у відповідному термі та ступінь його впливу на значення вихідного параметра), що дозволяє наблизити початкові точки пошуку до областей розташування екстремумів і прискорити процес оптимізації. Здобувачем розроблено метод донавчання діагностичних нейро-нечітких моделей, який передбачає виконання етапів видобування та угруповання коригувальних екземплярів, діагностування за якими за допомогою існуючої моделі призводить до некоректних результатів, а також побудову коригувального блоку, який узагальнює дані коригувальних екземплярів, і впровадження його у вже існуючу модель, що дозволяє адаптувати до зміни середовища функціонування існуючі діагностичні моделі шляхом їх модифікації з урахуванням інформації, отриманої в результаті нових спостережень.

Результати наукових досліджень, викладені у дисертаційній роботі, використані при підготовці дисциплін "Інтелектуальні системи", "Основи обчислювального інтелекту", "Еволюційне моделювання" на кафедрі програмних засобів НУ «Запорізька політехніка».

Проректор з науково-педагогічної роботи
та питань перспектив розвитку університету,
директор Інституту
інформатики та радіоелектроніки,
доктор технічних наук, професор



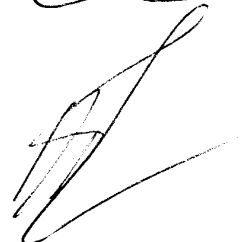
Д. М. Піза

Завідувач кафедри програмних засобів,
доктор технічних наук, професор



С. О. Субботін

Професор кафедри програмних засобів,
кандидат технічних наук, професор



В. І. Дубровін

ДОДАТОК В

Список публікацій здобувача за темою дисертації

в яких опубліковані основні наукові результати дисертації:

1. Олейник, А. А. Синтез диагностических и распознающих моделей на основе гибридных нейро-нечётких технологий вычислительного интеллекта : монография / А. А. Олейник, Т. А. Зайко, С. А. Субботин ; под ред. С. А. Субботина. – Харьков : ООО “Компания Смит”, 2014. – 284 с.

2. Методи та засоби оброблення великих даних в системах діагностування та розпізнавання образів : монографія / [С. О. Субботін, А. О. Олійник, В. М. Льовкін, Т. О. Колпакова, М. Ю. Пришляк, С. Ю. Леоценко, О.В. Корнієнко, Д.А. Каврін, Є.О. Гофман, О.Ю. Благодарьов] ; під заг. ред. С. О. Субботіна, А. О. Олійника. – Запоріжжя : ЗНТУ, 2018. – 228 с.

3. Subbotin, S. The Dimensionality Reduction Methods Based on Computational Intelligence in Problems of Object Classification and Diagnosis / S. Subbotin, A. Oliinyk // Recent Advances in Systems, Control and Information Technology. Advances in Intelligent Systems and Computing. – 2017. – Vol. 543. – P. 11–19. (Входить до міжнародних наукометричних баз **Scopus** та **Web of Science**).

4. Олійник, А. О. Видобування правил на основі дерев розв’язків та стохастичного пошуку / А. О. Олійник // Радіоелектроніка, інформатика, управління. – 2014. – № 2. – С. 110–119. (Входить до міжнародної наукометричної бази **Web of Science**).

5. Oliinyk, A. The decision tree construction based on a stochastic search for the neuro-fuzzy network synthesis / A. Oliinyk, S. A. Subbotin // Optical Memory and Neural Networks (Information Optics). – 2015. – Vol. 24, № 1. – P. 18–27. (Входить до міжнародної наукометричної бази **Scopus**).

6. Гофман, Е. А. Эволюционный метод синтеза деревьев решений / Е. А. Гофман, А. А. Олейник, С. А. Субботин // Штучний інтелект. – 2011. – № 2. – С. 6–14.

7. Олійник, А. О. Побудова асоціативних правил на основі інтелектуального стохастичного пошуку / А. О. Олійник // Математичні машини і системи. – 2015. – № 4. – С. 45–56.

8. Oliinyk, A. A stochastic approach for association rule extraction / A. Oliinyk, S. A. Subbotin // Pattern Recognition and Image Analysis. – 2016. – Vol. 26, № 2. – P. 419–426. (Входить до міжнародної наукометричної бази **Scopus**).

9. Subbotin, S. Diagnostic rule mining based on artificial immune system for a case of uneven distribution of classes in sample / S. Subbotin A. Oliinyk, V. Levashenko, E. Zaitseva // Communications – Scientific Letters of the University of Zilina. – 2016. – Vol. 3. – P. 4–12. (Входить до міжнародної наукометричної бази **Scopus**).

10. Олійник, А. О. Видобування продукційних правил на основі негативного відбору / А. О. Олійник // Радіоелектроніка, інформатика, управління. – 2016. – № 1. – С. 40–49. (Входить до міжнародної наукометричної бази **Web of Science**).

11. Subbotin, S. Induction of classification rules in case of uneven distribution of classes / S. Subbotin, A. Oliinyk, V. Levashenko, E. Zaitseva // Радіоелектронні і комп'ютерні системи. – 2016. – №. 6 (80). – P. 176–180.

12. Oliinyk, A. O. Parallel Method of Production Rules Extraction Based on Computational Intelligence / A. Oliinyk, S. Skrupsky, S. Subbotin, I. Korobiichuk // Automatic Control and Computer Sciences. – 2017. – Vol. 51, Issue 4. – P. 215–223. (Входить до міжнародних наукометричних баз **Scopus** та **Web of Science**).

13. Oliinyk, A. O. Experimental research and analysis of complexity of parallel method for production rules extraction / A. Oliinyk, S. Skrupsky, S. Subbotin

// Automatic Control and Computer Sciences. – 2018. – Vol. 52, Issue 2. – P. 89–99. (Входить до міжнародних наукометричних баз **Scopus** та **Web of Science**).

14. Oliinyk, A. A. The model for estimation of computer system used resources while extracting production rules based on parallel computations / A. A. Oliinyk, S. Yu. Skrupsky, V. V. Shkarupylo, S. A. Subbotin // Радіоелектроніка, інформатика, управління. – 2017. – № 1. – С. 142–152. (Входить до міжнародної наукометричної бази **Web of Science**).

15. Олейник, А. А. Мультиагентный метод оптимизации с адаптивными параметрами / А. А. Олейник // Штучний інтелект. – 2011. – № 1. – С. 83–90.

16. Олійник, А. О. Мультиагентний метод з опосередкованим зв'язком між агентами / А. О. Олійник // Радіоелектроніка, інформатика, управління. – 2010. – № 2. – С. 82–89. (Входить до міжнародної наукометричної бази **Web of Science**).

17. Олейник, А. А. Многомерный поиск на основе мультиагентного подхода / А. А. Олейник // Радиоэлектроника и информатика. – 2010. – № 2. – С. 51–55.

18. Олейник, Ан. А. Агентные технологии для отбора информативных признаков / Ан. А. Олейник, Ал. А. Олейник, С. А. Субботин // Кибернетика и системный анализ. – 2012. – № 2. – С. 113–125. (Входить до міжнародних наукометричних баз **Scopus** та **Web of Science**).

19. Oliinyk, A. A. Parallel multiagent method of big data reduction for pattern recognition / A. A. Oliinyk, S. Yu. Skrupsky, V. V. Shkarupylo, O. Yu. Blagodariov // Радіоелектроніка, інформатика, управління. – 2017. – № 2. – С. 82–92. (Входить до міжнародної наукометричної бази **Web of Science**).

20. Oliinyk, A. The System of Criteria for Feature Informativeness Estimation in Pattern Recognition / A. Oliinyk, S. Subbotin, V. Lovkin, O. Blagodariov, T. Zaiko // Радіоелектроніка, інформатика, управління. – 2017. –

№ 4. – С. 85–96. (Входить до міжнародної наукометричної бази **Web of Science**).

21. Oliinyk, A. Parallel method of big data reduction based on stochastic programming approach / A. Oliinyk, S. Subbotin, V. Lovkin, M. Pyashenko, O. Blagodariov // *Радіоелектроніка, інформатика, управління*. – 2018. – № 2. – С. 60–72. (Входить до міжнародної наукометричної бази **Web of Science**).

22. Олейник, А. А. Модель параметрического синтеза нейро-нечетких сетей в ярусно-параллельной форме / А. А. Олейник, С. Ю. Скрупский, С. А. Субботин // *Наукові праці Донецького національного технічного університету. Серія: "Інформатика, кібернетика та обчислювальна техніка"*. – 2014. – № 1 (19). – С. 106–113.

23. Oliinyk, A. O. Using Parallel Random Search to Train Fuzzy Neural Networks / A. O. Oliinyk, S. Yu. Skrupsky, S. A. Subbotin // *Automatic Control and Computer Sciences*. – 2014. – Vol. 48, Issue 6. – P. 313–323. (Входить до міжнародних наукометричних баз **Scopus** та **Web of Science**).

24. Oliinyk, A. A. Neural network synthesis based on evolutionary optimization / A. A. Oliinyk, S. A. Subbotin // *Системні дослідження та інформаційні технології*. – 2015. – № 1. – С. 77–86.

25. Oliinyk, A. O. Experimental Investigation with Analyzing the Training Method Complexity of Neuro-Fuzzy Networks Based on Parallel Random Search / A. O. Oliinyk, S. Yu. Skrupsky, S. A. Subbotin // *Automatic Control and Computer Sciences*. – 2015. – Vol. 49, Issue 1. – P. 11–20. (Входить до міжнародних наукометричних баз **Scopus** та **Web of Science**).

26. Олійник, А. О. Планування ресурсів паралельної обчислювальної системи при синтезі нейро-нечітких моделей для обробки великих даних / А. О. Олійник, С.Ю. Скрупський, С.О. Субботін, А.Ю. Благодарьов, Є.О. Гофман // *Радіоелектроніка, інформатика, управління*. – 2016. – № 4. – С. 61–69. (Входить до міжнародної наукометричної бази **Web of Science**).

27. Oliinyk, A. Additional training of neuro-fuzzy diagnostic models / A. Oliinyk, S. Subbotin, S. Leoshchenko, M. Ilyashenko, N. Myronova, Y. Mastinovsky // *Радіоелектроніка, інформатика, управління*. – 2018. – № 3. – С. 106–119. (Входить до міжнародної наукометричної бази **Web of Science**).

28. Oliinyk, A. A. Information Technology of Diagnosis Model Synthesis Based on Parallel Computing / A. A. Oliinyk, S. A. Subbotin, S. Yu. Skrupsky, V. M. Lovkin, T. A. Zaiko // *Радіоелектроніка, інформатика, управління*. – 2017. – № 3. – С. 139–151. (Входить до міжнародної наукометричної бази **Web of Science**).

29. Гофман, Е. А. Синтез нейро-нечётких сетей на основе деревьев решений для диагностирования и автоматической классификации по признакам / Е. А. Гофман, С. А. Субботин, А. А. Олейник // *Радіоелектроніка та інформатика*. – 2012. – № 2. – С. 58–62.

30. Oliinyk, A. O. Factor analysis of transaction data bases / A. O. Oliinyk, T. A. Zaiko, S. A. Subbotin // *Automatic Control and Computer Sciences*. – 2014. – Vol. 48, Issue 2. – P. 87–96. (Входить до міжнародних наукометричних баз **Scopus** та **Web of Science**).

31. Олейник, А. А. Синтез нейро-нечетких сетей на основе ассоциативных правил / А. А. Олейник, Т. А. Зайко, С. А. Субботин // *Кібернетика та системний аналіз*. – 2014. – Т. 50, № 3. – С. 27–38. (Входить до міжнародних наукометричних баз **Scopus** та **Web of Science**).

32. Oliinyk, A. Training Sample Reduction Based on Association Rules for Neuro-Fuzzy Networks Synthesis / A. Oliinyk, T. Zaiko, S. Subbotin // *Optical Memory and Neural Networks (Information Optics)*. – 2014. – Vol. 23, № 2. – P. 89–95. (Входить до міжнародної наукометричної бази **Scopus**).

які засвідчують апробацію матеріалів дисертації:

33. Гофман, Е. А. Использование деревьев решений для диагностирования автотранспортных средств / Е. А. Гофман, А. А. Олейник,

С. А. Субботин // Информационные управляющие системы и компьютерный мониторинг : II Всеукраинская научно-техническая конференция ИУС и КМ-2011, Донецк, 11–13 апреля 2011 г. : материалы конференции. – Донецк : ДонНТУ, 2011. – Т. 1. – С. 159–163.

34. Гофман, Е. А. Применение деревьев решений для редукции баз лингвистических правил / Е. А. Гофман, А. А. Олейник, С.А Субботин // Информационные технологии и автоматизация–2011 : материалы Всеукраинской научно-производственной конференции, Одесса, 12–14 октября 2011 р. : тезисы докладов. – Одесса : ОНАПТ, 2011. – С. 11–12.

35. Олейник, А. А. Извлечение продукционных правил на основе гибридных методов вычислительного интеллекта / А. А. Олейник // Сучасні проблеми і досягнення в галузі радіотехніки, телекомунікацій та інформаційних технологій : VIII міжнародна науково-практична конференція, Запоріжжя, 21–23 вересня 2016 р. : матеріали конференції. – Запоріжжя : ЗНТУ, 2016. – С. 324–325.

36. Олійник, А. О. Редукція великих масивів даних на основі паралельного мультиагентного підходу / А. О. Олійник, С. О. Субботін // Тиждень науки : науково-практична конференція, Запоріжжя, 18–21 квітня 2017 р. : матеріали конференції. – Запоріжжя : ЗНТУ, 2017. – С. 701–703.

37. Oliinyk, A. Development of the indicator set of the features informativeness estimation for recognition and diagnostic model synthesis / A. Oliinyk, S. Subbotin, V. Lovkin, S. Leoshchenko, T. Zaiko // Advanced Trends in Radioelectronics, Telecommunications and Computer Engineering : 14th International Conference TCSET'2018, Lviv-Slavske, 20-24 February 2018 : Conference proceedings. – Lviv : Lviv Polytechnic National University, 2018. – P. 903-908. (Входить до міжнародних наукометричних баз **Scopus** та **Web of Science**).

38. Олійник, А. О. Паралельний метод видобування продукційних правил / А. О. Олійник, О. Ю. Благодарьов // Комп'ютерні інтелектуальні

системи та мережі : Всеукраїнська науково-практична конференція, Кривий Ріг, 21-23 березня 2018 р. : тези доповідей. – Кривий Ріг: Видавничий центр ДВНЗ «Криворізький національний університет», 2018. – С. 157-160.

39. Oliinyk, A. Parallel data reduction method for complex technical objects and processes / A. Oliinyk, S. Leoshchenko, V. Lovkin, S. Subbotin, T. Zaiko // Dependable Systems, Services and Technologies, (DESSERT'2018) : The 9th IEEE International Conference, Kyiv, 24-27 May, 2018 : proceedings. – Los Alamitos: IEEE, 2018. – P. 496–501. (Входить до міжнародної наукометричної бази **Scopus**).

40. Oliinyk, A. Feature selection based on parallel stochastic computing / A. Oliinyk, S. Subbotin, V. Lovkin, S. Leoshchenko, T. Zaiko // Computer Science and Information Technologies, (CSIT'2018) : XIII International Scientific and Technical Conference, Lviv, 11-14 September, 2018 : proceedings. – Lviv: Vegha i Ko, 2018. – P. 347–351. (Входить до міжнародних наукометричних баз **Scopus** та **Web of Science**).

41. Олійник, А. О. Паралельний метод синтезу нейро-нечітких мереж / А. О. Олійник // Тиждень науки : науково-практична конференція, Запоріжжя, 14–18 квітня 2014 р. : матеріали конференції. – Запоріжжя : ЗНТУ, 2014. – Т. 2. – С. 128–130.

42. Олійник, А. О. Інтелектуальна інформаційна технологія параметричного синтезу нейро-фаззі мереж / А. О. Олійник, С. О. Субботін, С. Ю. Скрупський // Інформаційні технології : I Українська конференція молодих науковців ІТ–2014, Київ, 22–23 травня 2014 р. : матеріали конференції. – Київ : Інститут суспільства Київського університету імені Бориса Грінченка, 2014. – С. 126–128.

43. Subbotin, S. The Fully-Defined Neuro-Fuzzy Model Synthesis / S. Subbotin, A. Oliinyk // Data Stream Mining & Processing (DSMP): 2016 IEEE First International Conference, Lviv, 23-27 August 2016 : proceedings. – Lviv: NU "Lvivska Politeckhnika", 2016. – P. 9-14.

44. Олійник, А. О. Дослідження процесу синтезу нейро-нечітких мереж на векторному процесорі / А. О. Олійник, С. Ю. Скрупський, С. О. Субботін // Інформаційні управляючі системи та комп'ютерний моніторинг : V Всеукраїнська науково-технічна конференція ІУС КМ-2014, Донецьк, 22–23 квітня 2014 р. : матеріали конференції. – Донецьк : ДонНТУ, 2014. – Т. 1. – С. 371–375.

45. Subbotin, S. Individual prediction of the hypertensive patient condition based on computational intelligence / S. Subbotin, A. Oliinyk, S. Skrupsky // Information and Digital Technologies : International Conference IDT'2015, Zilina, 7–9 July 2015 : proceedings of the conference. – Zilina : Institute of Electrical and Electronics Engineers, 2015. – P. 336–344. (Входить до міжнародних наукометричних баз **Scopus** та **Web of Science**).

46. Олейник, А. А. Метод донавчання нейро-нечітких моделей / А. А. Олейник // Сучасні проблеми і досягнення в галузі радіотехніки, телекомунікацій та інформаційних технологій : IX міжнародна науково-практична конференція, Запоріжжя, 03–05 жовтня 2018 р. : матеріали конференції. – Запоріжжя : ЗНТУ, 2018. – С. 138–140.

47. Гофман, Є. О. Метод структурно-параметричного синтезу нейро-фаззі мереж / Є. О. Гофман, А. О. Олійник, С. О. Субботін // Сучасні інформаційні системи та технології : Міжнародна науково-практична конференція AIST–2012, Суми, 15–18 травня 2012 р. : матеріали конференції. – Суми : СумДУ, 2012. – С. 175–176.

48. Олейник, А. А. Выявление латентных признаков в транзакционных базах данных / А. А. Олейник, Т. А. Зайко, С. А. Субботин // Информатика та комп'ютерні технології : IX міжнародна науково-технічна конференція, Донецьк, 4–6 листопада 2013 р. : матеріали конференції. – Донецьк : ДонНТУ, 2013. – С. 233–236.

49. Олейник, А. А. Метод редукции данных для синтеза моделей неразрушающего контроля качества / А. А. Олейник, Т. А. Зайко,

С. А. Субботин // Информатика: проблемы, методология, технологии : XIV Международная конференция, Воронеж, 6–8 февраля 2014 г. : материалы конференции. – Воронеж : Издательский дом Воронежского государственного университета, 2014. – Т. 3. – С. 140–144.

50. Олійник, А. О. Редукція надлишкових екземплярів в транзакційних базах даних / А. О. Олійник, Т. А. Зайко, С. О. Субботін // Сучасні інформаційні системи та технології : III міжнародна науково-практична конференція AIST-2014, Суми, 14–16 травня 2014 р. : матеріали конференції. – Суми : СумДУ, 2014. – С. 97–98.

51. Субботін, С. О. Згорвальна нейронна мережа як парадигма для реалізації технології глибокого навчання / С. О. Субботін, А. О. Олійник, О. Ю. Благодарьов // Информатика, управління та штучний інтелект : Науково-технічна конференція, Харків, 26–27 листопада 2014 р. : матеріали конференції. – Харків : НТУ «ХПІ», 2014. – С. 73.

52. Kolpakova, T. Improved method of group decision making in expert systems based on competitive agents selection / T. Kolpakova A. Oliinyk, V. Lovkin // 2017 IEEE First Ukraine Conference on Electrical and Computer Engineering (UKRCON), Kyiv, May 29 – June 2, 2017 : conference proceedings. – Kyiv: Institute of Electrical and Electronics Engineers, 2017. – P. 939–943. (Входить до міжнародних наукометричних баз **Scopus** та **Web of Science**).

53. Oliinyk, A. A. Evolutionary method for solving the traveling salesman problem / A. Oliinyk, I. Fedorchenko, A. Stepanenko, M. Rud, D. Goncharenko // Problems of Infocommunications. Science and Technology : 5th International Scientific-Practical Conference PICST2018, Kharkiv, 9–12 October 2018 : proceedings of the conference. – Kharkiv: Kharkiv National University of Radioelectronics, 2018. – P. 331–338. (Входить до міжнародних наукометричних баз **Scopus** та **Web of Science**).

54. Fedorchenko, I. Genetic method of image processing for motor vehicle recognition / I. Fedorchenko, A. Oliinyk, A. Stepanenko, T. Zaiko, A. Svyrydenko,

D. Goncharenko [Electronic resource] // Proceedings of the Second International Workshop on Computer Modeling and Intelligent Systems (CMIS-2019), Zaporizhzhia, Ukraine, April 15-19, 2019. – P. 211-226. – (CEUR Workshop Proceedings, Vol. 2353). – Access mode: <http://ceur-ws.org/Vol-2353/paper17.pdf>. (Входить до міжнародної наукометричної бази **Scopus**).

55. Oliinyk, A. Development of Genetic Methods for Predicting the Incidence of Volumes of Emissions of Pollutants in Air / A. Oliinyk, I. Fedorchenko, A. Stepanenko, A. Katschan, Yu. Fedorchenko, A. Kharchenko, D. Goncharenko // Proceedings of the 2nd International Workshop on Informatics and Data-Driven Medicine IDDM 2019, Lviv, 11–13 November 2019 : proceedings of the workshop. – Lviv: Lviv Polytechnic National University, 2019. – P. 340–353. – (CEUR Workshop Proceedings, Vol. 2488). (Входить до міжнародної наукометричної бази **Scopus**).

які додатково відображають наукові результати дисертації:

56. Пат. 134493 Україна, МПК G06F 17/00. Спосіб відбору інформативних ознак великих даних для побудови розпізнавальних моделей / А. О. Олійник, В. М. Льовкін, (Україна); заявник Запорізький національний технічний університет. – № u2018 10874 ; заявл. 02.11.18 ; опубл. 27.05.19, Бюл. № 10/2019.

57. Пат. 70944 Україна, МПК G06F 19/24. Спосіб побудови дерев розв'язків для виявлення знань при діагностуванні виробів / Є. О. Гофман, А. О. Олійник, С. О. Субботін, (Україна); заявник Запорізький національний технічний університет. – № u2011 15678 ; заявл. 30.12.11 ; опубл. 25.06.12, Бюл. № 12.

58. Олійник, А. О. Синтез нейро-нечітких моделей для прогнозування стану здоров'я хворого на основі паралельних обчислень / А. О. Олійник // *Радіоелектроніка, інформатика, управління*. – 2015. – № 2. – С. 30–40.

59. Oliinyk, A. Combinatorial optimization problems solving based on evolutionary approach / A. Oliinyk, I. Fedorchenko, A. Stepanenko, M. Rud,

D. Goncharenko // The experience of Designing and Application of CAD systems (CADSM): 15th International Conference CADSM'2019, Polyana (Svalyava), 26 February –2 March 2019 : proceedings of the conference. – Lviv : Lviv Polytechnic National University, 2019. – P. 41-45. (Входить до міжнародної наукометричної бази **Scopus**).