

ГОЛОГРАФИЯ И НЕЙРОННЫЕ СЕТИ

В. Е. ИГНАТЬЕВ

Целью данной статьи является анализ современных тенденций в области голографической ассоциативной памяти на основе нейронных сетей, и показать, как идеи оптической голографической ассоциативной памяти послужили основой для построения цифровой нейронной ассоциативной памяти. На данный момент голографические нейронные сети все еще остаются малоизученными, и нашли слабое применение. В научной прессе присутствует малое количество статей, и практически отсутствуют специализированные книги. Все существующие программные пакеты для работы с голографическими нейронными сетями платные, что существенно осложняет доступ к их исследованию. Рассмотрим эволюцию и переход от обычных нейросетей до нейросетей на комплексных числах, далее до голографических нейронных сетей и многомерной голографической ассоциативной памяти.

Ключевые слова: голографическая ассоциативная память, нейросети, комплексные нейронные сети, голографические нейронные сети, многомерная голографическая ассоциативная память.

ВВЕДЕНИЕ

Ассоциативная память (АП) и вычисления на ее основе являются базисом человеческого разума, именно поэтому исследования в этой области вызывают такой бурный интерес у многих исследователей. В тоже время на аналогии между принципом работы голограммы и человеческой памяти обращали внимание Д. Габор, а позднее Ю.Н. Денисюк. В статье Д. Габора [1], уже ставшей классической, миру была представлена оптическая голографическая модель ассоциативной памяти (ОГАП). Позже, исследования такого типа памяти в трехмерных средах были сделаны ван Хирденом [2]. По мнению ван Хирдена, сходство некоторых свойств голограммы и мозга подтверждает гипотезу английского физиолога Берля [3] о том, что мозг хранит каждый бит информации не в одиночной пространственно-локализованной ячейке, а в виде одиночной пространственной гармонике возбуждения, заполняющей весь объем мозга.

Такой тип памяти имеет ряд преимуществ по сравнению с локализованными источниками памяти. Во-первых, в таком случае повреждение локальных участков памяти не приводит к полному исчезновению всей информации, а в некоторых случаях возможно даже дальнейшее восстановление утраченной информации. Во-вторых, вход в такую память можно осуществить из любого места. В-третьих, емкость такого рода памяти грандиозна и была теоретически оценена в [2]. В 1971 году Виславом [4] была предложена практическая реализация ОГАП.

Основой для использования голографии как ассоциативной памяти, заложена в самом принципе голограммы. Голограмма представляет из себя запись интерференционного паттерна на фоточувствительном материале, полученного путем интерференции

предметной и опорной когерентной волны, а также дальнейшее восстановление предметной волны, посредством освещения голограммы опорной волной, что можно трактовать как установление ассоциации или соответствия между предметной и опорной волной.

Другой технологией, послужившей основой для искусственной ассоциативной памяти, стали нейронные сети. После появления первых нейросетей [5], многие ученые быстро осознали возможность их применения в этой области. Так наиболее известной нейронной сетью такого типа является полносвязная сеть Хопфилда описанная в работе [6]. Эта работа пролила свет на то обстоятельство, что заимствованные из природы сети, состоящие из нейроподобных элементов, могут быть использованы в качестве вычислительного устройства. Что послужило толчком для многих исследователей из различных областей знания для дальнейшего изучения подобного класса сетей. При этом они преследовали двоякую цель: лучшее понимание того, как работает мозг, а также найти возможность применения мозгоподобных свойств этих сетей для решения проблем, которые не поддавались решению традиционными методами. Примечательно, что в дальнейшем, сети Хопфилда получили реализацию на голографических оптических корреляторах Вандер Люгта [7].

1. АССОЦИАТИВНАЯ ПАМЯТЬ НА ОСНОВЕ ОПТИЧЕСКОЙ ГОЛОГРАФИИ

Рассмотрим упрощенную версию записи голограммы, представленную на рисунке 1. Как мы видим из рисунка, две волны падают на фотографическую пластинку Р, одна волна опорная S, вторая объектная R, которая на самом деле представляет из себя волновой фронт $R(x, y)$. На плоскости пластины происхо-

дит интерференция двух волн с дальнейшей их регистрацией в фотоматериале.




Рис. 1. Запись голограммы

Математически опишем этот процесс, опорная волна выражается формулой $K = K_0 e^{-ikx}$, тогда распределение интенсивности в плоскости голограммы определяется выражением:

$$\begin{aligned}
 I(x, y) &= |R(x, y) + K_0 e^{-ikx}|^2 = \\
 &= |R(x, y)|^2 + K_0^2 + K_0 \overline{R(x, y)} e^{-ikx} + K_0 R(x, y) e^{-ikx} = \\
 &= I_A + I_B + I_C + I_D.
 \end{aligned}
 \tag{1}$$

Во время записи интерференционного рисунка на пленке, создается дифракционная решетка. При этом пропускная способность $t(x, y)$ пленки в каждом ее участке пропорциональна $I(x, y)$. Полученная таким способом запись называется голограммой.

Снова облучим голограмму опорным пучком. Результирующее поле может быть описано следующим образом:

$$\begin{aligned}
 O(x, y) &= t(x, y) K_0 e^{-ikx} = K_0 I(x, y) e^{-ikx} = \\
 &= K_0 (K_0^2 + |R(x, y)|^2) e^{-ikx} + K_0 \overline{R(x, y)} e^{-ikx} + \\
 &+ K_0 |R(x, y)| = (A + B) + C + D.
 \end{aligned}
 \tag{2}$$

Из формулы видно, что после всех преобразований у нас получилось три исходящих волны, как показано на рисунке 2. Но только волна D содержит в себе полностью и правильно восстановленный волновой фронт $R(x, y)$. Что примечательно, этот же способ может быть использован для восстановления опорной волны S, однако в этом случае требуется облучить голограмму непосредственно волновым




Рис. 2. Схема восстановления голограммы

фронтом $R(x, y)$. Эта идея впервые была выдвинута Габором в его работе [1] и заложила основу голографической ассоциативной памяти.

Если вместо опорной волны использовать волновой фронт, полученный путем облучения другого объекта, тогда интерференционный паттерн двух волновых фронтов от двух объектов будет представлять из себя ассоциацию двух объектов. После облучения, полученной таким образом голограммы, волной одного из объектов, мы восстановим изображение другого объекта, и наоборот. На одной фотопластинке можно записать не одну пару объектов, а множество различных ассоциативных пар. При этом все записанные пары будут находиться в суперпозиции по отношению друг другу.

ОГАП имеет ряд преимуществ. Во-первых, запись информации имеет распределенный характер, т. е. сохраненная информация сохранена на всей плоскости голограммы, а точнее во всем ее объеме. Что в свою очередь обеспечивает высокую помехоустойчивость и защиту от локальных повреждений. Повреждение части голограммы не приводит к потере всей информации, а приводит лишь к небольшим потерям и ухудшению качества голограммы или восстановленных изображений по голограмме. Во-вторых, высокая плотность записи. Как было описано выше на одной голограмме может быть записано огромное количество голограмм и ассоциативных пар.

2. ИСКУССТВЕННЫЕ НЕЙРОСЕТИ, ИСПОЛЬЗУЮЩИЕ КОМПЛЕКСНЫЕ ЧИСЛА (НИКЧ)

Вычислительные возможности зачастую зависят от способа представления информации. Традиционно искусственные нейронные сети (ТНС) работают с вещественными числами, что для некоторых случаев накладывает определенные ограничения. Это послужило причиной создания альтернативных конструкций искусственного нейрона. Одной из таких новых парадигм стало создание нейронов на комплексных числах использующих для работы с данными комплексные числа и преобразование Фурье [8, 9, 10, 11, 12]. Интересная модель комплексного нейрона была представлена в работе [13]. В работе был описан новый тип нейронов для работы со спайковыми или импульсными нейронными сетями предложенными Хопфилдом [14] в 1995 году. Импульсные нейроны были нацелены прежде всего на более корректное моделирование реальных биологических нейронов, в которых, как известно, информация кодируется длительностью импульсов [15]. Было показано, что представление данных в виде комплексных чисел для такого рода сетей существенно облегчает решение многих задач.

Нейрон на комплексных числах структурно похож на традиционный нейрон, за исключением того, что он работает с комплексными числами. Поэтому

внешние данные, которые обычно представляют из себя действительные числа, должны быть сконvertированы в комплексные. Каждый комплексный нейрон имеет набор входов, образующих вектор P . Для того, чтобы сконvertировать вещественное значение входных данных для одного входа p_i , необходимо воспользоваться следующей формулой:

$$p_i = e^{i \left(\frac{R}{R_{\max}} \frac{\pi}{2} \right)}, \quad (3)$$

где R – это вещественное число входных данных, R_{\max} – максимальное значение входных данных. Из формулы видно, что диапазон входных вещественных значений должен быть конечен. Функция агрегации для комплексного нейрона точно такая же, как и для обычного персептрона:

$$q = wp. \quad (4)$$

Здесь $p \in C^n$ – вектор-столбец входных компонент p_i , $w \in C^n$ – вектор-строка весов w_i нейрона. Важно заметить, что в отличии от функции агрегации для обычного нейрона, эта функция агрегации нелинейная по отношению к вещественным входным данным.

Функция активации для нейрона на комплексных числах может быть различной, однако чаще всего используется функция вида:

$$a = \begin{cases} 0, & \text{if } |q| < T \\ 1, & \text{if } |q| \geq T \end{cases}, \quad (5)$$

где a и T – вещественные числа, а q – комплексное число. Поскольку функция активации работает с вещественным числом, то q может быть заменена на более простое выражение для дальнейшего вычисления, а именно на:

$$r = |q|^2. \quad (6)$$

Правило тренировки определяется формулой:

$$\Delta w = \Delta \theta = \theta_{new} - \theta_{old}. \quad (7)$$

Комплексный нейрон использует комплексные числа для представления данных. При этом если мы посмотрим на формулу его обучения (7), то можем увидеть, что это очень грубо соответствует самому простому случаю голографической ассоциативной памяти, когда ассоциация устанавливается между двумя когерентными волнами. Однако ассоциативную память идентичную ОГАП на них построить невозможно, поскольку сам по себе нейрон на комплексных числах идентичен традиционному персептрону.

3. ГОЛОГРАФИЧЕСКИЕ НЕЙРОННЫЕ СЕТИ (ГНС)

Голографические нейронные сети — это уже отнюдь не новый тип искусственных нейронных сетей. Они были предложены Сазерлендом [16], такие сети сильно отличаются от классических нейронных сетей [5], непривычны во многих аспектах и представляют из себя альтернативу обычным нейросетям.

Их ключевое отличие от традиционных нейросетей – это голографический нейрон. За счет своих особенностей, голографический нейрон преодолевает ограничения, имеющиеся в нейроне на комплексных числах. Он гораздо более мощный чем нейрон традиционной нейронной сети и НИКЧ, заменяет собой целую нейронную сеть. Поэтому, для построения нейронной сети из таких нейронов, требуется гораздо меньше элементов, топология получается очень простая, состоящая из малого количества нейронов, а в некоторых случаях их достаточно несколько штук или всего один нейрон. Достигается такая эффективность за счет использования суперпозиции информации в одном объеме записывающей среды или пространстве памяти, что зависит от технологии реализации нейросети. В грубом приближении это напоминает ОГАП. При этом, оптическая голография представляет из себя запись трехмерного объекта на двухмерной среде, вмещающей внутри себя всю необходимую информацию для дальнейшего восстановления сохраненного изображения. Следует обратить внимание, что в процессе записи как бы теряется одно из измерений, как результат при чистой голографической записи, а если говорить терминами АП – при кодировании и декодировании, повышается плотность записи информации. Аналогичные процессы происходят и в голографических нейронных сетях за счет использования комплексных чисел для работы с данными, что является ключевой их особенностью, сильно отличая их ГНС и НИКЧ.

Голографический нейрон можно рассматривать как черный ящик. Схема голографического нейрона изображена на рисунке 3.




Рис. 3. Голографический нейрон

Процесс работы с ним основан на принципе подачи на вход паттернов стимулов и получении соответствующего ответа, который представляет из себя так же паттерн выходов. Сазерленд, создатель ГНС, вместо термина паттерн часто использует термин поле [16]. Входной паттерн или поле можно записать как одномерную матрицу или поле, соответствующий набор выходов, так же можно выразить матрицей или полем:

$$S = [S_1, S_2, \dots, S_n],$$

$$R = [R_1, R_2, \dots, R_m]. \quad (8)$$

Важно отметить, что каждый входной и выходной вектор представляет из себя комплексное число. Набор входных векторов представляет из себя матрицу, состоящую из комплексных чисел и выражается формулой:

$$S = [\lambda_1 e^{i\theta_1}, \lambda_2 e^{i\theta_2}, \dots, \lambda_n e^{i\theta_n}]. \quad (9)$$

В наборе выходных векторов также все элементы заменяются комплексными числами:

$$R = [\gamma_1 e^{i\phi_1}, \gamma_2 e^{i\phi_2}, \dots, \gamma_m e^{i\phi_m}]. \quad (10)$$

В данных формулах амплитуда представляет из себя уровень вероятности данных, она изменяется в диапазоне [0.0, 1.0]. Толковать это нужно следующим образом, это уровень доверия к данным, например, если входными данными служит статистика, то это будет вероятность события. Фаза, также, как и для НИКЧ, это актуальные значения данных. Однако в качестве функции конвертации здесь используется функция сигмоида, имеющая следующий вид:

$$\theta_k = 2\pi \left(1 - e^{-\frac{\mu - S_k}{\sigma}} \right)^{-1}, \quad (11)$$

где σ – стандартное отклонение распределения значений (дисперсия); μ – среднее отклонение (математическое ожидание).

Использование сигмоиды в качестве функции конвертации вещественных входных значений, полученных к примеру, с измерительных приборов, дает существенное преимущество ГНС перед НИКЧ, поскольку здесь входные значения могут быть в диапазоне $[-\infty, +\infty]$. При этом полученные фазовые значения всегда будут в диапазоне $[0, 2\pi]$, с точкой симметрии в π .

Базовая идея использования комплексных чисел, как и в НИКЧ это представление входящей информации в виде вектора на комплексной плоскости. Обучение такой нейронной сети осуществляется за счет определения разницы между поворотом или фазовым углом каждого входного вектора с каждым выходным вектором. Из этого можно вывести следующие принципы обучения голографического нейрона, во-первых, каждый нейрон должен содержать внутри себя матрицу размерности $n \times m$ состоящую из комплексных чисел, во-вторых, обучение голографического нейрона сводится к нахождению всех значений элементов этой матрицы. Получить ее можно из следующего выражения:

$$[M] = [S]^T \cdot [R], \quad (12)$$

$[S]^T$ – это Эрмитово-сопряженная матрица входной матрицы $[S]$. Получается она следующим образом, на примере матрицы $[\overline{A}]$ с комплексными элементами, получается из исходной матрицы $[A]$ транспонированием и заменой каждого элемента комплексно-сопряженным. Для матрицы $[A]$ в комплексных числах преобразование можно выразить следующими формулами:

$$\text{для } [A] = (a_{j,k}) \quad [\overline{A}] = (\overline{a_{k,j}}),$$

$$\text{для каждого } a = e^{i\vartheta} \quad \bar{a} = e^{-i\vartheta},$$

$$\text{или } a = x + iy \quad \bar{a} = x - iy,$$

$$\text{где } x = \cos \vartheta \quad y = \sin \vartheta. \quad (13)$$

Обучение одной ассоциации между стимулом S и желаемым ответом R осуществляется за счет сохранения корреляции между каждым входным j-м стимулом и k-м выходом в матрице памяти, что в аналогично обучению НИКЧ и выражается формулой:

$$m_{jk} = \lambda_j \gamma_k e^{i(\phi_k - \theta_j)}. \quad (14)$$

Как уже было упомянуто выше, голографические нейронные сети используют принцип суперпозиции информации в одном пространстве памяти. Корреляционная матрица $[M]$ описывает процесс обучения для одного паттерна стимулов и соответствующего ему паттерна выходов. Поэтому представленную выше технику, по аналогии с ОГАП, можно расширить до записи обучения большого набора входных паттернов стимулов на одной матрице голографического нейрона, что в данном случае представляет собой общее пространство памяти. Введем нумерацию матриц $[M]$ для каждого из паттернов, тогда для первого паттерна это будет $[M_1]$, для второго $[M_2]$, для p-го будет $[M_p]$. Все паттерны стимулов могут по принципу суперпозиции быть записанными в одной матрице корреляции $[X]$ по следующему правилу:

$$[X] = [M_1] + [M_2] + [M_3] + \dots + [M_p], \quad (15)$$

где знак «+» обозначает следующую операцию:

$$\text{для } [A] = (a_{j,k}), [B] = (b_{j,k})$$

$$[A] + [B] = (a_{j,k} + b_{j,k}). \quad (16)$$

Заметим еще раз, что $a_{j,k}$ и $b_{j,k}$ представляют из себя комплексные числа. Результирующая корреляционная матрица для группы векторов будет иметь следующий вид:

$$[X] = \begin{bmatrix} \sum_p \lambda_1 \gamma_1 e^{i(\varphi_{p,1}-\theta_{p,1})} & \sum_p \lambda_2 \gamma_1 e^{i(\varphi_{p,2}-\theta_{p,1})} & \dots \\ \sum_p \lambda_1 \gamma_2 e^{i(\varphi_{p,1}-\theta_{p,2})} & \sum_p \lambda_2 \gamma_2 e^{i(\varphi_{p,2}-\theta_{p,2})} & \dots \\ \sum_p \lambda_1 \gamma_3 e^{i(\varphi_{p,1}-\theta_{p,3})} & \sum_p \lambda_2 \gamma_3 e^{i(\varphi_{p,2}-\theta_{p,3})} & \dots \\ \vdots & \vdots & \dots \\ \vdots & \vdots & \dots \\ \vdots & \vdots & \dots \end{bmatrix}. \quad (17)$$

Теперь рассмотрим процесс получения ответа из предварительно обученной сети. Получение ответа от сети связано прежде всего со считыванием выходного вектора $[R]$, при подаче на вход соответствующего входного вектора $[S]$. Обозначим через $[S]^*$ новый вектор входных стимулов или точнее паттерн. Тогда процесс извлечения ответа из сети будет описываться следующим перемножением матриц:

$$[R] = \frac{1}{c} [S]^* \cdot [X], \quad (18)$$

где c – это фактор нормализации. В качестве фактора нормализации может быть взято просто число входных стимулов, или любая другая функция. Обычно он вычисляется по следующей формуле:

$$c = \sum_1^n \lambda_k^*. \quad (19)$$

Как мы видим из вышеприведенного материала, ГНС построена по принципу ОГАП и наследует все основные ее преимущества. А именно: сохранение информации носит распределенный характер по всей матрице голографического нейрона, вся информация находится в суперпозиции по отношению друг к другу, за счет суммирования матриц корреляции для одного входного и выходного паттерна, благодаря чему достигается высокая плотность сохранения данных.

4. МНОГОМЕРНАЯ ГОЛОГРАФИЧЕСКАЯ АССОЦИАТИВНАЯ ПАМЯТЬ (МГАП)

ГНС Сазерленда [16], описанные в предыдущей главе, явилась одной из первых пионерских работ по голографической нейронной ассоциативной памяти. Рассмотренная Ханом [17], многомерная ассоциативная память обобщает в себе логику ГНС работающей с данными на двумерной плоскости, и представляет данные в форме многомерных комплексных чисел как точек на гиперсфере. Таким образом формула для одного отдельного стимула имеет следующий вид:

$$S_k = \lambda_k e^{i \left(\sum_j^{d-1} i_j \theta_{j,k} \right)}. \quad (20)$$

Стимул представляет из себя функцию от $S(\lambda_k, \theta_1^k, \theta_2^k, \dots, \theta_{d-1}^k)$. При этом каждый из фазовых компонентов θ_j^k это сферическая проекция вдоль оси i_j . Амплитудное значение λ_k несет тоже значение что и в ГНС. Используя формулу для одного стимула можно получить выражения для набора входных значений (паттерна) и соответствующих им ответов:

$$S = \left[\lambda_1 e^{i \left(\sum_j^{d-1} i_j \theta_{j,1} \right)}, \lambda_2 e^{i \left(\sum_j^{d-1} i_j \theta_{j,2} \right)}, \dots, \lambda_k e^{i \left(\sum_j^{d-1} i_j \theta_{j,n} \right)} \right],$$

$$R = \left[\lambda_1 e^{i \left(\sum_j^{d-1} i_j \theta_{j,1} \right)}, \lambda_2 e^{i \left(\sum_j^{d-1} i_j \theta_{j,2} \right)}, \dots, \lambda_k e^{i \left(\sum_j^{d-1} i_j \theta_{j,m} \right)} \right]. \quad (21)$$

В целом логика для кодирования и извлечения данных из такой памяти остается такой же, как и для ГНС. Формулы получения матрицы корреляции и получения ответа аналогичны соответствующим формулам (17), (18), (19), для ГНС. В целом МГАП наиболее точно соответствует ОГАП.

ЗАКЛЮЧЕНИЕ

Голографические нейронные сети – в некоторых аспектах более мощные и удобные, чем традиционные типы нейросетей. Стоит отметить простоту их использования, а также их быструю обучаемость. В статьях Роберта Мангера [18] [19] [20], приводятся результаты практического применения ГНС, а так же их анализ. В сравнении с ТНС, диапазон возможности их применения шире, к примеру, в работе [19] показано использование ГНС для сжатия информации, на что не способны ТНС. Однако во многих случаях, как указывается в [18], их применение требует учета особенностей ГНС. Заложенные базовые принципы построения таких сетей из классической голографии, дает ряд ценных свойств, таких как компактность хранения информации и использование комплексных чисел для работы с информацией, что во многих случаях является просто более удобным представлением, чем использование вещественных чисел, а в некоторых ситуациях разрешает фундаментальные ограничения.

Следует так же отметить, что в статье не были затронуты и освещены достаточно глубоко темы появления ошибки обучения и разбалансировки ГНС после записи в одну сеть большого количества пат-


тернов [21], а также лишь вскользь была затронута тема бимодального способа представления данных [17] и уровня вероятности данных [21].

На сегодняшний день НИКЧ, ГНС и МГАП получили различные способы реализации. Имеются как программные пакеты, например, HNet созданный компанией AND Corporation, так и специализированные аппаратные решения [21], [13]. Активно обсуждаются и предлагаются решения на основе оптоэлектроники.

Литература

- [1] D. Gabor, «Associative Holographic Memories», IBM Journal of Research and Development, т. 3, pp. 156-159, 1969.
- [2] P. J. van Heerden, «A New Optical Method of Storing and Retrieving», Applied Optics, pp. 387-392, 1993.
- [3] B. R. J., «Properties of a mass of cell capable of regenerating pulses,» Phil. Trans. Roy. Soc.(London), № B240, p. 55, 1956.
- [4] D. Willshaw, «Holography, Associative Memory, and Inductive Generalization,» HiAn85, pp. 83-102, 1985.
- [5] R. Hecht-Nielsen, Neurocomputing, Massachusetts: Addison-Wesley, 1990.
- [6] J. J. Hopfield, «Neural networks and physical systems with emergent collective computational abilities», Proceedings of the National Academy of Sciences U.S.A, т. 79, pp. 2554-2558, April 1982.
- [7] K. Y. L. H. Y. P. D. Hsu, «Holographic Implementation of a Fully Connected Neural Network», Proc IEEE, т. 78, 1990.
- [8] T. Nitta, «An extension of the back-propagation algorithm to complex numbers», Neural Networks, т. 10, № 8, pp. 1391-1415, 1997.
- [9] N. a. P. F. Benvenuto, «On the complex backpropagation algorithm», IEEE Transactions on Signal Processing, т. 40, № 4, pp. 967-969, 1992.
- [10] H. a. H. S. Leung, «The complex backpropagation algorithm», IEEE Transactions on Signal Processing, т. 39, № 9, pp. 2101-2104, 1991.
- [11] G. M. a. K. C. Georgiou, «Complex domain backpropagation», IEEE Transactions on Circuits and Systems—II: Analog and Digital Signal Processing, т. 39, № 5, p. 330-334, 1992.
- [12] M. R. a. H. Y. Smith, «A data extrapolation algorithm using a complex domain neural network», IEEE Transactions on Circuits and Systems—II: Analog and Digital Signal Processing, т. 44, № 2, pp. 143-147, 1997.
- [13] D. R. a. S. I. H. E. Michel, «Proceedings of the International Conference on VLSI», в CMOS Implementation of phase-encoded complex-valued artificial neural networks, 2004.
- [14] J. J. Hopfield, «Pattern recognition computation using action potential timing for stimulus representation», Nature, т. 376, pp. 33-36, 1995.
- [15] W. a. B. C. M. Maass, «Pulsed Neural Networks,» The MIT Press, 1998.
- [16] J. G. Sutherland, «Holographic model of memory, learning and expression,» International J. Of Neural Systems, т. 1, № 3, p. 256-267, 1990.
- [17] J. I. Khan, Ph.D. Dissertation, Department of Electrical Engineering, University of Hawaii, 1995.
- [18] R. Manger, «The lecture presented at the Mathematical Colloquium in Osijek organized by Croatian», в Holographic neural networks, Department of Mathematics, University of Zagreb, 1998.
- [19] R. Manger, «Proceedings of the 18th International Conference on Information Technology Interfaces», в Can holographic neural networks be used for data compression, Zagreb, 1996.
- [20] R. a. M. M. Manger, «Proceedings of the 16th International Conference on Information Technology Interfaces», в Using holographic neural networks for currency exchange rates prediction, University Computing Centre, Zagreb, 1994.
- [21] J. Sutherland, «NEURAL NETWORKS». USA Патент 5,515,477, 7 5 1996.
- [22] D. Gabor, «A New Microscopic Principle», Nature, pp. 777-778, 1948.
- [23] T. Poggio, «On holographic models of memory», Kybernetik, т. 12, № 4, pp. 237-238, 1973.
- [24] K. J. I. & D. Yun, «Holographic Image Archive», т. 20, № 4, 1996.

Поступила в редколлегию 17.05.2018



Игнатъев Вадим Евгеньевич, аспирант кафедры физической и биомедицинской электроники и комплексных информационных систем факультета радиофизики, биомедицинской электроники и компьютерных систем ХНУ им. В. Н. Каразина. Область научных интересов – оптическая голография и голографические информационные технологии.

УДК 004.8

Игнатъев В. Е. **Голографія та нейромережі** / В. Е. Игнатъев // Прикладна радіоелектроніка: наук. – техн. журнал. – 2018. – Том 17, № 1, 2. – С. 42–48.

Метою даної статті є аналіз сучасних тенденцій у сфері голографічної асоціативної пам'яті на основі нейронних мереж, і показати, як ідеї оптичної голографічної асоціативної пам'яті лягли в основу для побудови цифрової нейронної асоціативної пам'яті. На сучасний момент голографічні нейронні мережі все ще залишаються маловивченими, і не знайшли широкого застосування. В науковій пресі присутня мала кількість статей, і практично відсутні спеціалізовані книги. Всі існуючі програмні пакети для роботи з голографічними нейронними мережами платні, що істотно ускладнює їх дослідження. Розглянемо еволюцію і перехід від звичайних нейромереж до нейромереж на комплексних числах, далі до голографічних нейронних мереж і багатовимірної голографічної асоціативної пам'яті.

Ключові слова: голографічна асоціативна пам'ять, нейромережі, комплексні нейронні мережі, голографічні нейронні мережі, багатовимірні голографічна асоціативна пам'ять.

Лл.3. Бібліогр.:24 найм.

UDC 004.8

Ignatiev V. E. **Holography and neural networks** / V. E. Ignatiev // Applied Radio Electronics: Sci. Journ. – 2018. – Vol. 17, № 1, 2. – P. 42–48.

The main aim of this paper is to analyze modern trends in the sphere of a holographic associative memory based on neural networks, and to show how the optical holographic associative memory ideas have formed the basis of creating new digital neuron associative memory. At present the holographic neural networks still remain little-studied and have found a narrow application. There is not extensive scientific literature in the form of articles on this topic and specialized books are not practically available. All the existing programming packages and frameworks for working with holographic neural networks are pay, which significantly complicates their study. The paper considers evolution and transition from conventional neural networks to complex number neural ones and further to holographic neural networks and multidimensional holographic associative memory.

Keywords: holographic associative memory, neural networks, complex neural networks, holographic neural networks, multidimensional holographic associative memory.

Fig. 3. Ref.: 24 items.