

*О.В. ЗУБКОВ, канд. техн. наук, С.А. ШЕЙКО канд. техн. наук,  
В.Н. ОЛЕЙНИКОВ, канд. техн. наук, В.М. КАРТАШОВ, д-р техн. наук,  
И.В. КОРЫТЦЕВ, канд. техн. наук, С.И. БАБКИН, канд. техн. наук*

## **ИССЛЕДОВАНИЕ ЭФФЕКТИВНОСТИ ДЕТЕКТИРОВАНИЯ И РАСПОЗНАВАНИЯ ИЗОБРАЖЕНИЙ ДРОНОВ ПО ВИДЕОПОТОКУ**

### **Введение**

В Европе и других странах мира постепенно ужесточаются ограничения на зоны полета дронов. К зонам, в которых запрещены полеты, относятся: военные объекты, аэродромы, места скопления людей, автомагистрали, тюрьмы, промышленные предприятия [1, 2]. Эти ограничения связаны с обеспечением безопасности людей и конфиденциальностью информации. Поэтому растет спрос на современные электронные системы обнаружения и классификации дронов для контроля периметров охраняемых территориях [3]. Одним из вариантов подобных систем являются системы анализа видеоизображения охранных камер видеонаблюдения. Данная статья посвящена исследованию эффективности обнаружения дронов по видеопотоку стационарной видеокамеры. При обработке видеопотока возможно применение двух основных подходов: анализ всего изображения с использованием нейронной сети и анализ фрагментов изображения, в которых обнаружено движение объектов. Первый подход реализован в алгоритме YOLO на базе нейронной сети DarkNet [4]. Для его применения требуется подготовка обучающей базы изображений с дронами и другими движущимися объектами, обучение и тестирование сети. Однако анализ возможностей данного алгоритма говорит о ряде его ограничений. Первое ограничение – это сложность математической обработки, что делает невозможным реализацию обработки изображений в реальном масштабе времени на базе компьютерных процессоров с малым количеством ядер. При применении процессора i7 в сочетании с библиотекой OpenCV и операционной системой Linux предельная скорость обработки – до четырех кадров в секунду. Для обработки видеопотока в реальном масштабе времени необходимо применение высокопроизводительных GPU типа NVIDIA GeForce 1080 [5]. Однако при обнаружении дронов основным является второе ограничение алгоритма YOLO. Перед подачей на нейронную сеть любое изображение с видеокамеры должно быть пересчитано во входное, соответствующее нейронной сети с максимальным разрешением 416x416 пикселей [6]. Размер обнаруживаемого на этом изображении объекта не должен быть меньше 7x7 пикселей. Например, при горизонтальном размере квадрокоптера DJI Phantom 3 0,35м, угле обзора видеокамеры наблюдения 60° и ширине изображения 416 пикселей на входе сети для алгоритма YOLO можно оценить значение предельного расстояния обнаружения. Оно не превышает 18 м. В зонах с запретом на полеты дронов такой дальности обнаружения недостаточно, так как эти зоны занимают значительные площади. Для таких зон дальность обнаружения должна быть не менее 50 – 100м. Некоторым исследователям [6] удалось повысить входное разрешение алгоритма YOLO до 832x832 пикселя. Однако это увеличение нельзя считать существенным и оно требует значительного увеличения быстродействия устройства обработки изображения. Анализ существующих алгоритмов обнаружения и классификации объектов по видеопотоку камеры позволил сформулировать ряд задач для исследования, решение которых позволит создать недорогую систему обнаружения и классификации дронов на значительных расстояниях. К ним относятся: обнаружение дронов на расстояниях не менее 50 – 100 м и возможность применения недорогих вычислительных устройств или блоков для обработки изображения видеокамеры. Для решения сформулированных задач исследований авторами был разработан алгоритм, сочетающий высокую производительность, эффективность распознавания и возможность обработки изображений с любым разрешением.

## Алгоритм обнаружения и классификации движущихся объектов

Разработанный алгоритм обнаружения и классификации движущихся объектов состоит из двух этапов: 1) обнаружение на текущем кадре всех фрагментов изображения, в которых выявлено движение; 2) подача массива этих фрагментов на вход обученной нейронной сети для их классификации.

Первый этап обработки изображения состоит из следующих шагов:

1) Преобразование цветного изображения в оттенки серого, и выполнение нормализации его яркости для уменьшения влияния изменений интенсивности освещения под действием суточных и погодных факторов. Нормализация яркости выполнялась по формуле [7]

$$G_{i,j} = 255 \frac{P_{i,j} - I_{\min}}{I_{\max} - I_{\min}}, \quad (1)$$

где – яркость пикселей исходного изображения;  $i = 1, 2, \dots, H$ ;  $j = 1, 2, \dots, W$ ;  $H$  и  $W$  – высота и ширина изображения соответственно;  $I_{\min}$  – минимальное значение исходной яркости изображения;  $I_{\max}$  – максимальное значение исходной яркости изображения;  $G_{i,j}$  – пиксель изображения с нормализованной гистограммой.

2) Выделение всех движущихся фрагментов изображения в текущем видеокадре на неподвижном фоне. На этом шаге исследований была проанализирована эффективность работы адаптивных моделей заднего фона изображений, таких как MOG, MOG2, KNN, GMG, CNT, GSOC, LSBP [13 – 20]. Результатом работы этих методов является черно-белое изображение, в котором черным цветом отображается неподвижный фон, а белые фрагменты изображения соответствуют областям движения (рис. 1).

Критериями эффективности являются: быстрдействие работы модели и количество ложных контуров движущихся объектов в видеокадре.

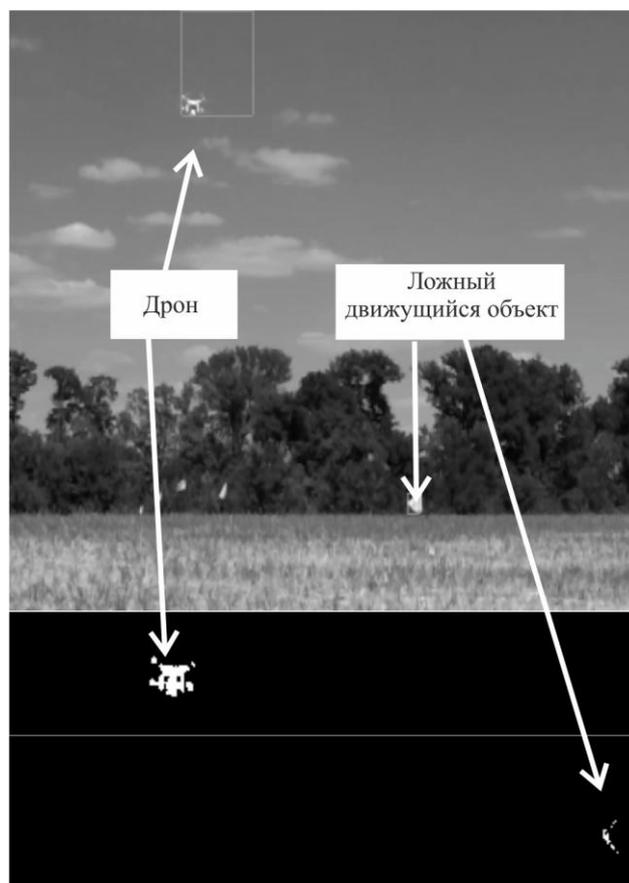


Рис. 1. Пример результата выделения на неподвижном фоне движущихся объектов: квадрокоптера и флажка

3) Применение ко всем фрагментам изображения, в которых обнаружено движение, алгоритма истории движения. Одной из наших приоритетных задач является обнаружение дрона на значительных расстояниях – до 100 м и более. При таких дальностях фрагмент изображения, содержащий дрон, очень мал. Например, при разрешении видеокамеры 1920x1080, угле ее обзора 60° на расстоянии 116 м изображение DJI Phantom 3 имеет размеры 5x5 пикселей. Столь малый фрагмент соизмерим с фрагментами, в которых обнаруживается движение под действием колебаний листвы деревьев, травы и т.д. Поэтому анализ движения производится на некотором интервале времени. Для этого создается фоновое изображение в оттенках серого с тем же разрешением, что и исходное.

На него накладывается результат работы одного из алгоритмов MOG, GMG, MOG2, KNN, CNT, GSOC, LSBP после обработки каждого кадра с видеокамеры. Перед наложением интенсивность каждого пиксела фонового изображения уменьшается на величину

$$\Delta I = \frac{255}{\Delta t \cdot FPS} \quad (2)$$

где 255 – предельная интенсивность пикселей;  $\Delta t$  – интервал анализа истории движения, с;  $FPS$  – частота кадров в секунду. В результате на фоновом изображении происходит наложение контуров движущихся объектов в группе кадров за интервал  $\Delta t$  и движущийся объект представляется результирующим контуром со значительно большей площадью, чем в одиночном кадре (рис. 2).



Рис. 2. Изображение, которое содержит историю движения двух объектов: квадрокоптера DJI Phantom 3 и флажка

4) Для дальнейшего анализа выбираются контуры с площадью, превышающей заданное пороговое значение, то есть происходит частичное отсечение колебаний листвы деревьев и травы. Все контуры, удовлетворяющие этому критерию, будем считать контурами условно движущихся объектов. Также для каждого условно движущегося объекта в текущем кадре вычисляются его координаты для его локализации в полном изображении и вырезка изображений этих объектов с целью подачи на вход нейронной сети.

Второй этап обработки изображений заключается в классификации фрагментов изображений, соответствующих областям движения, с применением нейронных сетей. Сначала был проанализирован перечень подвижных объектов, которые могут оказаться в зоне видимости

видеокамеры. К ним относятся: дроны, люди, домашние животные, птицы, насекомые, легковые и грузовые автомобили, лошади, лодки и корабли, самолеты, фрагменты движущихся облаков, фрагменты качающихся ветвей деревьев и травы. Всего для исследований использовалось 12 классов объектов. После этого были созданы модели классических и сверточных нейронных сетей, проведено их обучение и экспериментальная проверка.

### Проведение экспериментов

Для экспериментальной проверки эффективности разработанного алгоритма на протяжении трех сезонов (лето, осень, зима) проводились видеозаписи полетов дронов. Для записи видео использовалась видеокамера Dahua DH-IPC-HFW2431RP-ZAS-IRE6 с разрешением 2688(H)x1520(V). Камера была настроена с разрешением 1920x1080 и углом обзора 60°. Запись видео производилась при различных погодных условиях в дневное и вечернее время на территории города и в пригородной зоне. В экспериментах использовались две модели квадрокоптеров: DJI Phantom 4 и Hubsan x4 air h501m. Для определения расстояния от видеокамеры до квадрокоптера во время полета дрона проводилась запись его GPS координат с последующей привязкой момента начала полета к видеозаписи стационарной видеокамеры. Пример одной из рассчитанных траекторий приведен на рис. 3.

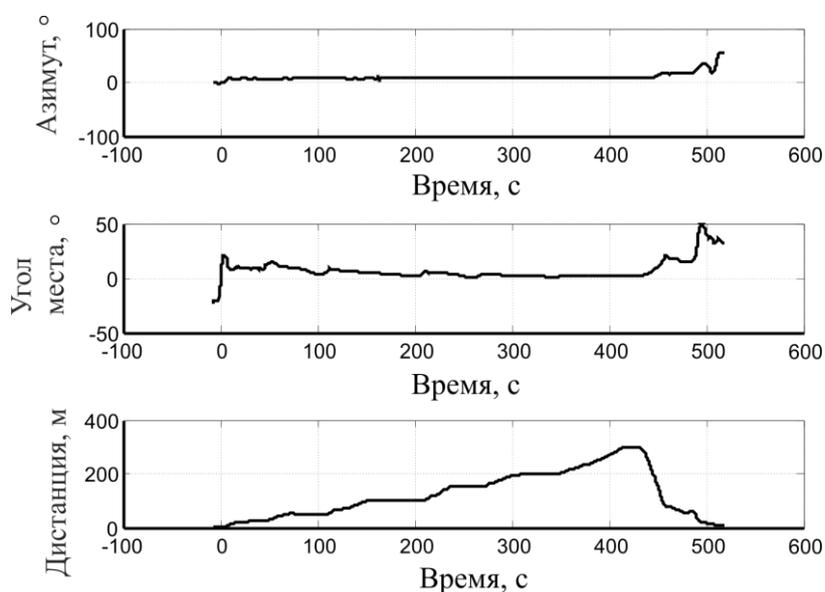


Рис. 3. Пример траектории движения квадрокоптера, вычисленный по результатам логирования GPS координат квадрокоптера

### Подготовка баз данных для обучения и тестирования нейронных сетей

Для обучения и тестирования моделей нейронных сетей авторами статьи были созданы наборы данных изображений с четырьмя классами объектов: дроны, насекомые, фрагменты листвы деревьев и травы, фрагменты неба с облаками. Для составления набора данных изображений с дронами с ресурса YouTube было скачано порядка 300 видеороликов с полетами порядка 14 модификаций различных дронов. Авторами статьи был разработан специальный видеоредактор на языке Python в среде PyCharmCommunity. С его помощью из видеок кадров вырезаны 5000 изображений дронов, и каждое изображение автоматически сохранено с разрешениями: 5x5, 9x9, 13x13, 27x27, 49x49, 64x64, 128x128 пикселей. Также эти видео использованы для создания наборов данных изображений с фрагментами деревьев, облаков и травы. 4000 изображений использовались на этапе обучения нейронных сетей, а 1000 изображений – для их тестирования после окончания обучения (рис. 4).

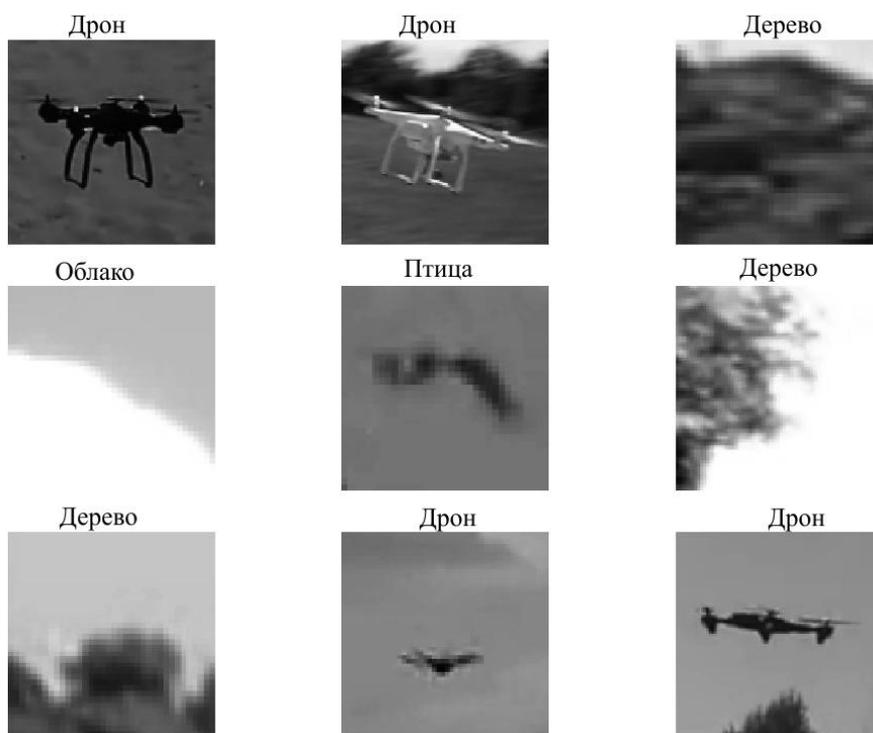


Рис. 4. Примеры изображений дронов, фрагментов облаков, листы деревьев и травы из созданных наборов данных

Аналогично был разработан набор данных изображений насекомых.

Наборы данных для таких классов объектов, как: легковые и грузовые автомобили, животные, птицы, люди, самолеты, лодки и корабли были взяты из готовых наборов данных CIFAR-10 с сайта <https://www.cs.toronto.edu/~kriz/cifar.html>. Набор данных каждого класса содержит 4500 цветных изображений с разрешением 32x32 пиксела. Данный сетевой ресурс также содержит набор данных для тестирования обученной сети.

#### **Результаты экспериментальных исследований выделения движущих объектов на неподвижном фоне**

Обработка видеофайлов проводилась с использованием программного обеспечения MiniConda и PyCharmCommunity, а также с применением библиотеки компьютерного зрения OpenCV v4.

При анализе эффективности работы алгоритма MOG мы изменяли его параметры: количество кадров, на основании которых рассчитывается модель фона, количество гауссовых смесей, коэффициент шума и уровень шума. Диапазон значений оптимального количества кадров для построения модели фона находится в пределах 80 – 130, что соответствует временному интервалу порядка 3,2 – 5,2с при частоте кадров видекамеры 25 кадров/с. При уменьшении этого числа наблюдается ухудшение выделения объекта и его дробление на группу более мелких частей. С увеличением числа кадров, по которому строится модель, существенно увеличивается время адаптации модели, что негативно сказывается в ситуациях изменения глобальной освещенности пространства (например, в момент, когда туча закрывает солнце или сильный ветер образует облако пыли). По нашим оценкам, метод позволяет обрабатывать до 10 – 11 кадров/с при разрешении камеры 1920x1080 пикселей. Под обработкой подразумевается не только работа самого алгоритма MOG, но и построение истории движения по 100 кадрам, а также детектирование контуров всех условно движущихся объектов, которые выделены на неподвижном фоне. Оптимальным диапазоном значений параметра “уровень шума” модели MOG является диапазон величин 20 – 25, он соответствует обнаружению летящего дрона до расстояния 120 – 140м. При уменьшении этого параметра вдвое

наблюдается значительное увеличение количества контуров условно движущихся объектов до 2 – 3 раз при отсутствии изменений общей интенсивности освещенности и без движения крупных объектов. При резких изменениях общей освещенности или движении крупных объектов количество контуров возрастает в 3 – 8 раз. С увеличением значения параметра “уровень шума” вдвое количество контуров сокращается, но снижается дальность обнаружения дрона до 50 – 60 м. Диапазон оптимальных значений параметра “количество гауссовых смесей” находится в пределах 4 – 8. С двукратным увеличением значения этого параметра снижается скорость обработки кадров до 8 – 9 кадров/с. При двукратном уменьшении значения этого параметра количество условно движущихся объектов увеличивается в 1,2 раза. Значение параметра “коэффициент шума” слабо влияет на результат обнаружения движущихся объектов.

При исследовании эффективности работы алгоритма MOG2 мы анализировали влияние количества кадров, на основании которых рассчитывается модель фона и порог на квадрате расстояния Махаланобиса между пикселем и моделью. Значения первого параметра следует выбирать из диапазона 100 – 140, что соответствует скорости обработки до 11 – 13 кадров/с. Увеличение этого значения приводит к существенному снижению скорости обработки до 3 – 4 кадров/с в моменты резкого изменения общей освещенности и до 9 – 10 кадров/с – при отсутствии глобальных изменений в видеокадре. Значения второго параметра следует выбирать из диапазона 100 – 150. Уменьшение величины этого параметра вдвое приводит к увеличению числа условно движущихся объектов в 2 – 6 раз, а увеличение величины этого параметра свыше 160 приводит к снижению дальности обнаружения дрона. Так, при величине этого параметра порядка 200 дальность снижается до 90 м.

При реализации алгоритма KNN было проанализировано влияние количества кадров, по которому рассчитывается модель и порога на квадрате расстояния между пикселем и образцом. Диапазон рабочих значений первого параметра находится в диапазоне 100 – 200. При этом достигается скорость обработки видеопотока 11 – 12 кадров/с. Дальнейшее увеличение величины этого параметра приводит к значительному повышению числа обнаруживаемых условно движущихся объектов. Оптимальный для нашей задачи диапазон значений второго параметра в пределах от 5000 до 10000. Уменьшение значения этого параметра приводит к существенному увеличению числа обнаруживаемых условно движущихся объектов, а увеличение значения этого параметра приводит к уменьшению дальности обнаружения ниже 120 м и разделению крупных объектов на группу более мелких.

Тестирование алгоритма GMG показало его высокую чувствительность к движению облаков, листвы деревьев, травы и чрезвычайно низкую скорость работы – порядка 1 – 3 кадров/с. Аналогичными недостатками обладает алгоритм CNT.

Применение алгоритма GSOC позволяет достичь скорости обработки видеопотока до 5 – 6 кадров/с и дальности обнаружения дрона до 90 м.

Итогом анализа стал выбор моделей MOG, MOG2, KNN для реализации алгоритма выделения движущихся объектов на неподвижном фоне для их дальнейшей классификации с применением нейронных сетей.

### **Результаты экспериментальных исследований обнаружения дронов с применением нейронных сетей**

Для проведения исследований была выбрана популярная открытая библиотека машинного обучения Keras, совместимая с TensorFlow. Она была подключена к платформе MiniConda, и для написания программ обучения сетей и их тестирования использовался язык программирования Python. Для обучения сетей и тестирования их эффективности применялись описанные выше наборы данных, часть из которых была создана авторами статьи, а часть – загружена из открытых баз данных. Основными критериями анализа были: скорость обработки данных, вероятность правильного распознавания и вероятность ложного обнаружения дрона.

С точки зрения достижения высоких скоростей обработки данных целесообразно использовать простые последовательные полносвязные модели сети. Дополнительный прирост производительности обеспечивает преобразование цветного изображения объекта распознавания в оттенки серого и его дальнейшая классификация нейронной сетью. Вторым широко распространенным в практических задачах классом нейросетей являются сверточные сети. Эти сети прекрасно зарекомендовали себя в алгоритмах, подобных YOLO, и обладают возможностью распараллеливания операций обработки, инвариантны к повороту изображения, что актуально для различных ракурсов наблюдения дрона и его кренов во время полета. Основным недостатком таких сетей является сложность настройки параметров сети, так как их количество велико, а процесс обучения длителен.

Для исследования эффективности простых полносвязных сетей были выбраны три модели. Первая модель состоит из входного слоя (нормированных значений яркостей пикселей изображения), одного промежуточного слоя из 1024 нейронов и выходного слоя с 12 выходами, соответствующими 12 классам объектов классификации. Во второй модели добавлен еще один промежуточный слой из 256 нейронов, а в третьей – два промежуточных слоя из 256 и 120 нейронов соответственно. На вход сети подавались изображения в градациях серого с разрешением 27x27 пикселей. Графики зависимостей точности обучения и потерь от количества эпох обучения приведены на рис. 5.

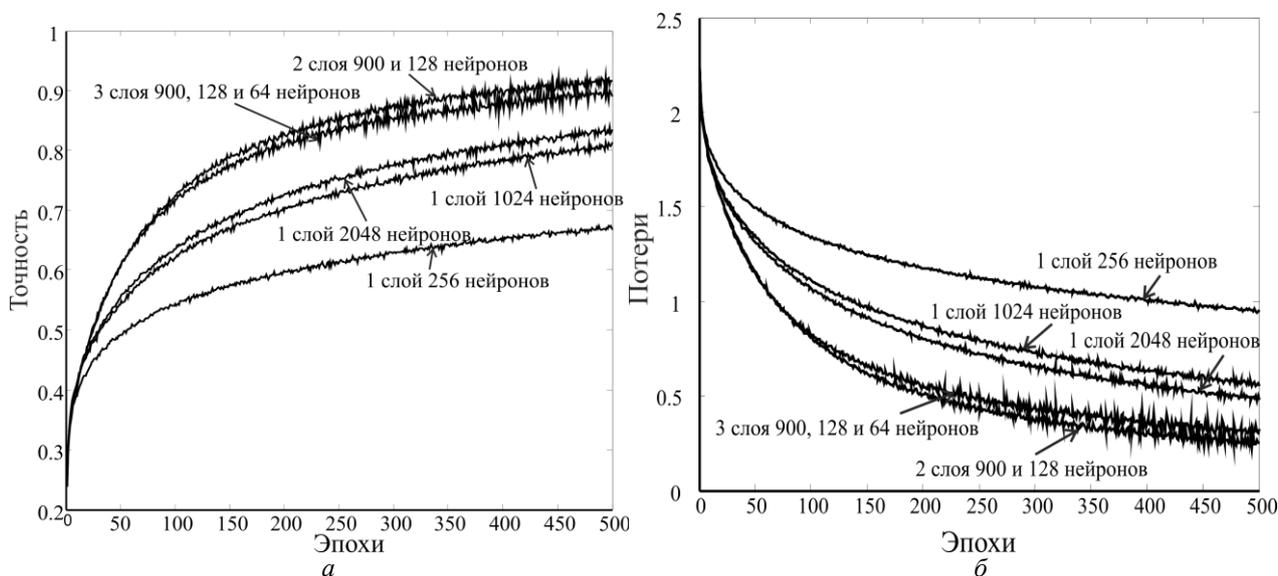


Рис. 5. Зависимости точности обучения (а) и потерь (б) полносвязных нейронных сетей от количества эпох обучения

Анализ зависимостей, приведенных на рис. 5, показывает: 1) для сетей с одним промежуточным слоем целесообразно использовать не менее 1000 нейронов в этом слое; 2) при увеличении количества промежуточных слоев свыше двух точность обучения начинает снижаться.

Тестирование обученной нейронной сети проводилась двумя способами. Первый – классический способ, при реализации которого используются тестовые наборы данных, состоящие из 1000 изображений дронов и от 500 до 1000 изображений на каждый из остальных классов.

Второй способ – тестирование при обработке снятых нами видеороликов с полетами дронов. Этот способ заключается в следующей последовательности действий:

- после окончания формирования модели заднего фона с применением алгоритмов MOG, MOG2 или KNN для каждого кадра потокового видео выделяются контуры условно движущихся объектов;

- каждый контур аппроксимируется квадратом со стороной, равной наибольшему из продольных размеров контуров;
- из общего изображения вырезается фрагмент, соответствующий координатам этого квадрата;
- разрешение фрагмента изображения пересчитывается в соответствующее обученной нейронной сети и преобразуется в оттенки серого;
- после обработки фрагмента изображения нейронной сетью принимается решение об обнаружении дрона. Критерий обнаружения – максимальное значение вероятности, соответствующее классу дрона из имеющихся классов объектов;
- по окончании обработки фрагмента видео с полетом дрона на расстояниях до 60 м формируются результирующие оценки вероятности верной классификации дронов  $p_t$  и вероятности ложного принятия решения  $p_f$  о наличии дрона.

Значения точности распознавания для тестовых наборов данных приведены в табл. 1.

Таблица 1

Значение	Тестовые наборы	Обработка видео	
	Accuracy	$p_t$	$p_f$
1 layer 256 neurons	0,5	0,23	0,09
1 layer 1024 neurons	0,81	0,63	0,051
1 layer 2048 neurons	0,78	0,58	0,059
2 layers 900 and 128 neurons	0,83	0,66	0,043
3 layers 900, 128 and 64 neurons	0,81	0,65	0,045

На основании результатов тестирования и экспериментальной проверки моделей полносвязных сетей был сделан вывод об их низкой эффективности для решения поставленной задачи. Поэтому было решено проанализировать эффективность работы сверточных сетей.

Для обучения сверточных нейронных сетей использовались ранее созданные наборы данных, содержащие 12 классов объектов. Однако при обучении сетей и их тестировании использовались цветные изображения, а не преобразованные в оттенки серого. Мы также решили увеличить объем базы для обучения за счет добавления в обучающие наборы копий исходных изображений, к которым были применены несколько аффинных преобразований: поворот изображения на угол  $45^\circ$ , зеркальное горизонтальное отражение. Первое преобразование позволяет смоделировать крены при полете дрона, второе преобразование связано с особенностями конструкции дронов. Дроны имеют, как правило, симметричную конструкцию, а большинство других объектов, таких как птицы, автомобили, кошки, собаки при виде сбоку не обладают симметрией. Для исследований использовались сети, состоящие из нескольких сверточных, одного полносвязного промежуточного и выходного слоев. К результатам сверток применялась функция MaxPool. Обучение проводилось в течение 50 эпох. Характеристики проанализированных сетей представлены в виде табл. 2.

Таблица 2

Номер модели	Количество сверток в сверточных слоях				Число нейронов в полносвязном слое
1	16	32			512
2	16	32			1024
3	16	32	64		512
4	16	32	64		1024
5	32	64	128		512
6	32	64	128	256	512

Графики зависимостей точности обучения и обнаружения дронов на тестовом наборе данных от количества эпох обучения приведены на рис. 6.

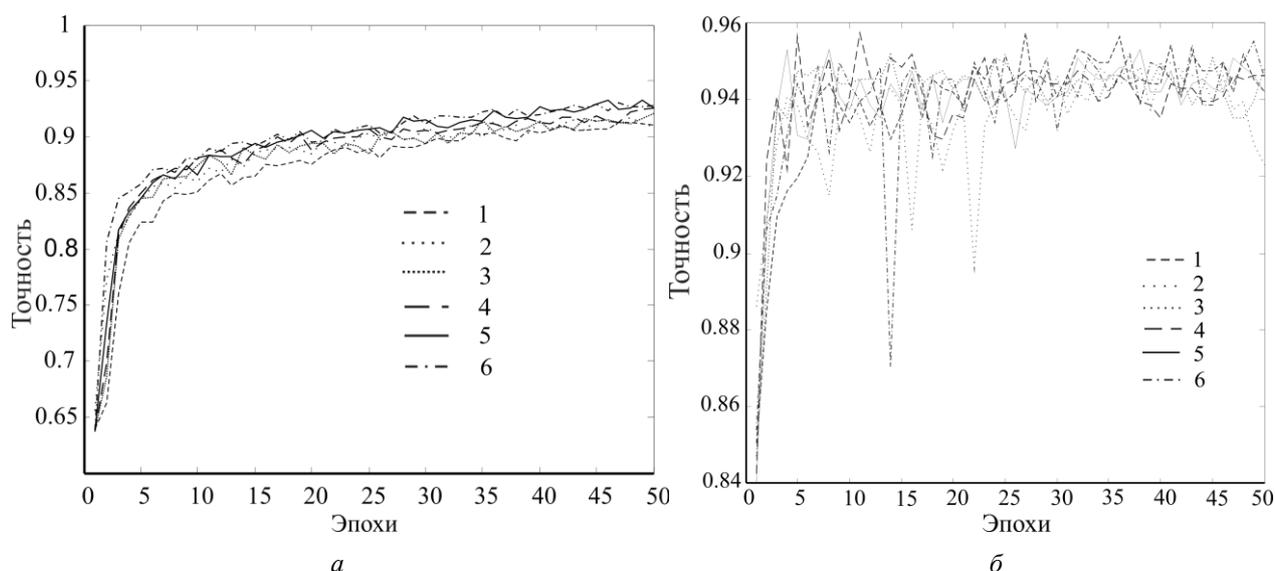


Рис. 6. *a* – график зависимостей точности обучения от количества эпох обучения; *б* – график зависимостей точности обнаружения дронов на тестовом наборе данных от количества эпох обучения

Анализ полученных зависимостей позволил сделать следующие выводы:

- значения точности проанализированных моделей сверточных сетей отличаются несущественно в пределах 3 %;
- точность на обучающем наборе данных ниже, чем на тестовом, что объясняется дополнением исходного набора изображений копиями этих изображений, к которым применялись аффинные преобразования;
- наилучшие результаты показали 5-я и 6-я модели сверточных сетей;
- использование в полносвязном слое свыше 512 нейронов не повышает точности.

Дополнительные исследования, результаты которых не приведены на рис. 6, показали, что снижение количества нейронов в полносвязном слое ниже 256 негативно сказывается на результирующей точности. Также дополнительные исследования с сетями, содержащими пять сверточных слоев, показали, что эти сети не позволяют повысить точность в сравнении с моделями 5 и 6.

Эффективность работы сверточных сетей также была проанализирована на совокупности снятых видеороликов. Результаты этих исследований приведены в табл. 3.

Таблица 3

Номер модели	$P_t$	$P_f$
1	0,85	0,01
2	0,85	0,008
3	0,87	0,007
4	0,88	0,006
5	0,88	0,005
6	0,89	0,007

Для обученной сети с номером 3 были проведены исследования достоверности обнаружения в зависимости от расстояния до объекта. Чтобы оценить достоверность мы использовали созданные ранее наборы данных в разных разрешениях от 5x5 до 128x128 пикселей. Разрешение каждого из изображений перед подачей на вход сети пересчитывалось в формат 32x32 пикселей. Для каждого из разрешений рассчитывалось соответствующее значение рас-

стояния исходя из угла зрения видеокамеры  $60^\circ$  и разрешения видеокамеры  $1920 \times 1080$  пикселей. Результат исследований представлен на рис. 7.

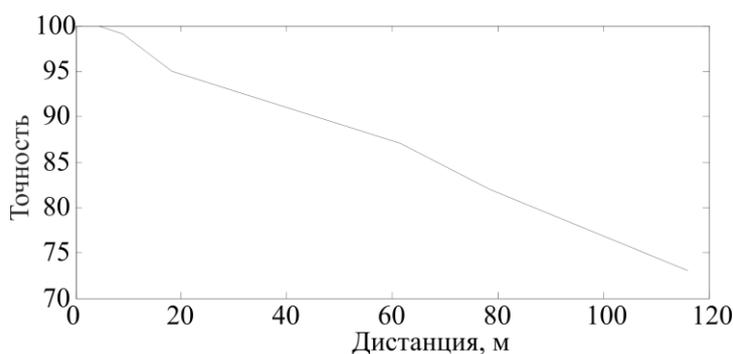


Рис. 7. Зависимость точности обнаружения от расстояния до дрона

## Выводы

Разработан и экспериментально протестирован алгоритм обработки видеопотока стационарной видеокамеры наблюдения, позволяющий обнаруживать дроны на значительных расстояниях. Алгоритм разделен на два основных этапа: обнаружение всех движущихся объектов и их дальнейшая классификация. В сравнении с существующими алгоритмами, такими как YOLO, у алгоритма нет ограничений на разрешение обрабатываемого изображения. Поэтому для камер высокого разрешения (4К, 8К и т.д.) можно повысить дальность обнаружения дронов пропорционально увеличению разрешения камеры. Дополнительным преимуществом является возможность классификации не только дронов, но и других движущихся объектов, таких как: автомобили, люди, животные, что актуально для охранных систем. Эту возможность обеспечивает нейронная сеть, классифицирующая 12 типов подвижных объектов. Экспериментальная проверка предложенного алгоритма доказала его работоспособность и высокую скорость обработки видеопотока (не ниже 8 кадров/с) без использования GPU аналогичных NVIDIA GeForce 1080. Применение моделей простых полносвязных нейронных сетей для классификации движущихся объектов оказалось неэффективным при обработке видеопотока камеры, так как точность классификации на реальных видеопотоках значительно ниже, чем на обучающем и тестовом наборах данных. Тестирование моделей сверточных сетей доказало их эффективность для поставленной задачи, так как результаты экспериментальной обработки видеопотоков идентичны результатам обучения и тестирования на наборах данных.

Предложенный алгоритм позволяет обнаруживать и распознавать движущиеся объекты с разрешением не ниже, чем  $5 \times 5$  пикселей, что соответствует дальностям до 120 м при разрешении камеры FullHD и угле обзора  $60^\circ$ . Полученное значение точности распознавания порядка 89 %, на наш взгляд, может быть повышено благодаря дальнейшему совершенствованию обучающих баз для выбранных нейронных сетей и выбору более оптимальной модели сети. Планируется продолжение исследований в этом направлении.

## Список литературы:

1. <https://dronerules.eu/en/recreational/regulations>
2. BBC (2018) Charges over drone drug smuggling into prisons. <https://www.bbc.com/news/uk-england-43413134>.
3. Jean-Paul Yaacoub, Hassan Noura, Ola Salman, Ali Chehab. Security analysis of drones systems // Attacks, limitations, and recommendations: Internet of Things. Volume 11, pages 1-39, 2020.
4. Kartashov V. M., Oleynikov V. N., Sheyko S. A., Koryttsev I. V., Babkin S.I., Zubkov O.V. Peculiarities of small-sized unmanned aerial vehicles detection and recognition // Telecommunications and Radio Engineering. Volume 78, Issue 9, pages 771-781, 2019.
5. Deep Learning on Multi Sensor Data for Counter UAV Applications – A Systematic Review. Stamatiou Samaras, Eleni Diamantidou, Dimitrios Ataloglou, Nikos Sakellariou, Anastasios Vafeiadis, Vasilis Magoulianitis, Antonios

- Lalas, Anastasios Dimou, Dimitrios Zarpalas, Konstantinos Votis, Petros Daras, Dimitrios Tzovaras. *Sensors (Basel)* 2019 Nov; 19(22): 4837. Published online 2019. Nov 6. doi: 10.3390/s19224837.
6. Redmon J., Divvala S., Girshick R. and Farhadi A. You Only Look Once: Unified, Real-Time Object Detection // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, pages 779-788, 2016, doi: 10.1109/CVPR.2016.91.
  7. Hao Liu<sup>1</sup>, Fangchao Qu<sup>1</sup>, Yingjian Liu<sup>1</sup>, Wei Zhao<sup>1</sup>, Yitong Chen A drone detection with aircraft classification based on a camera array IOP // Conf. Series: Materials Science and Engineering 322 (2018).
  8. Ammar A., Koubaa A., Ahmed M., Saad A. Aerial Images Processing for Car Detection using Convolutional Neural Networks: Comparison between Faster R-CNN and YoloV3. Preprints 2019, 2019100195 (doi: 10.20944/preprints201910.0195.v1).
  9. Song Han, W. Shen, Z. Liu Deep Drone: Object Detection and Tracking for Smart Drones on Embedded System // Computer Science, 2016.
  10. Wen Shao, Rei Kawakami, Ryota Yoshihashi, Shaodi You, Hidemichi Kawase & Takeshi Naemura Cattle detection and counting in UAV images based on convolutional neural networks // International Journal of Remote Sensing Volume 41- NO 1, pages 31-52, 2020.
  11. Unlu E., Zenou E., Riviere N. et al. Deep learning-based strategies for the detection and tracking of drones using several cameras // IPSJ T Comput Vis Appl Vol. 11, 2019.
  12. Marcin Kocioleka, Michał Strzelecki, Rafał Obuchowicz. Does image normalization and intensity resolution impact texture classification? // Computerized Medical Imaging and Graphics Volume 81, 2020.
  13. Tomasz Hyla, Natalia Wawrzyniak. Automatic Ship Detection on Inland Waters: Problems and a Preliminary Solution // ICONS 2019: The Fourteenth International Conference on Systems, pages 56-60.
  14. T. Trnovszký, P. Sýkora, R. Hudec. Comparison of Background Subtraction Methods on Near Infra-Red Spectrum Video Sequences // Procedia Engineering Volume 192, pages 887-892, 2017.
  15. Yao G., Lei T., Zhong J., Jiang, P., Jia, W. Comparative Evaluation of Background Subtraction Algorithms in Remote Scene Videos Captured by MWIR Sensors // Sensors 2017, Vol. 17, pages 19-45.
  16. Marcomini L. A., Cunha A. L. A Comparison between Background Modelling Methods for Vehicle Segmentation in Highway Traffic Videos. // Computer Vision and Pattern Recognition, 2018.
  17. Kartashov V., Oleynikov V., Zubkov O., Sheiko S. Optical detection of unmanned air vehicles on a video stream in a real-time // The Fourth International Conference on Information and Telecommunication Technologies and Radio Electronics (UkrMiCo'2019), 9–13 September 2019, Odessa, Ukraine, 4 p.
  18. Moulay A. Akhloufi, Sebastien Arola, Alexandre Bonnet. Drones Chasing Drones: Reinforcement Learning and Deep Search Area Proposal. Drones, Vol. 58, No.3, 2019.
  19. Yamashita R., Nishio M., Do R.K.G. et al. Convolutional neural networks: an overview and application in radiology // Insights Imaging Vol. 9, pages 611–629, 2018.
  20. Vivienne Sze, Yu-Hsin Chen, Tien-Ju Yang, Joel Emer Efficient Processing of Deep Neural Networks: A Tutorial and Survey Computer Science, 2017.

*Поступила в редколлегию 29.09.2020*

*Сведения об авторах:*

**Зубков Олег Викторович** – канд. техн. наук, доцент, Харьковский национальный университет радиоэлектроники, доцент кафедры медиаинженерии и информационных радиоэлектронных систем, Украина, e-mail: [Oleh.zubkov@nure.ua](mailto:Oleh.zubkov@nure.ua), ORCID: <https://orcid.org/0000-0002-8528-6540>

**Шейко Сергей Александрович** – канд. техн. наук, доцент, Харьковский национальный университет радиоэлектроники, доцент кафедры медиаинженерии и информационных радиоэлектронных систем, Украина, e-mail: [sergiy.sheiko@nure.ua](mailto:sergiy.sheiko@nure.ua), ORCID: <https://orcid.org/0000-0003-1638-4478>

**Олейников Владимир Николаевич** – канд. техн. наук, доцент, Харьковский национальный университет радиоэлектроники, профессор кафедры медиаинженерии и информационных радиоэлектронных систем, Украина, e-mail: [vladimir.oleinikov@nure.ua](mailto:vladimir.oleinikov@nure.ua), ORCID: <https://orcid.org/0000-0001-7197-9760>

**Карташов Владимир Михайлович** – д-р техн. наук, профессор, Харьковский национальный университет радиоэлектроники, заведующий кафедрой медиаинженерии и информационных радиоэлектронных систем, Украина, e-mail: [volodymyr.kartashov@nure.ua](mailto:volodymyr.kartashov@nure.ua), ORCID: <https://orcid.org/0000-0001-8335-5373>

**Корытцев Игорь Васильевич** – канд. техн. наук, доцент, Харьковский национальный университет радиоэлектроники, профессор кафедры медиаинженерии и информационных радиоэлектронных систем, Украина, e-mail: [igor.koryttsev@nure.ua](mailto:igor.koryttsev@nure.ua), ORCID: <https://orcid.org/0000-0003-1875-5534>

**Бабкин Станислав Иванович** – канд. техн. наук, Харьковский национальный университет радиоэлектроники, старший научный сотрудник кафедры медиаинженерии и информационных радиоэлектронных систем, Украина, e-mail: [pri.res@nure.ua](mailto:pri.res@nure.ua), ORCID: <https://orcid.org/0000-0003-4903-3551>