

Нейросетевое детектирование групповых объектов испытаний по гиперспектральным маркерам при внешнетраекторных измерениях

Иван Андреевич Кулешов

Министерство обороны РФ, Войсковая часть 03080, Приозёрск, Республика Казахстан

ibnkuleshov@mail.ru, <https://orcid.org/0000-0002-8046-9065>

Аннотация. Актуализирована задача детектирования элементов групповых объектов лётных испытаний. Актуальность задачи обусловлена нарастающей потребностью в метрологическом обеспечении внешнетраекторных измерений при испытаниях образцов перспективных многоагентных систем с элементами – летательными аппаратами. Проанализированы существующие алгоритмы детектирования объектов, применяемые в современных оптико-электронных станциях (системах). По результатам анализа сделан вывод о несоответствии данных алгоритмов требованиям, предъявляемым при испытаниях групповых объектов, в частности из-за сложности селекции объектов на атмосферном фоне. Для детектирования групповых объектов предложено использовать дополнительные высокоинформативные признаки, отражающие физическую природу наблюдаемых объектов: особенности формы спектра света, отражённого от различных материалов. Предложено выявлять признаки в процессе предварительного гиперспектрального анализа объектов испытаний с последующим сокращением размерности данных. Чтобы исключить ошибки, возникающие при вращении и частичном перекрытии объектов, рекомендовано применять нейросетевые методы и приборы, в частности нейросетевой детектор YOLO v2. Предложены вариант организации данных для его обучения, а также архитектура детектора, обеспечивающая высокие точность и скорость обработки информации. Данные характеристики детектора были подтверждены экспериментально на основании изображений, экспортируемых из модели сеанса внешнетраекторных измерений. Предложен порядок реализации нейросетевого детектирования групповых объектов испытаний. Полученные результаты актуальны для решения вопросов аппаратно-программного обеспечения следящих оптико-электронных систем.

Ключевые слова: гиперспектральный снимок, свёрточная сеть, детектор, групповой объект, внешнетраекторные измерения

Для цитирования: Кулешов И. А. Нейросетевое детектирование групповых объектов испытаний по гиперспектральным маркерам при внешнетраекторных измерениях // Измерительная техника. 2022. № 3. С. 17–23. <https://doi.org/10.32446/0368-1025it.2022-3-17-23>

Neural network detection of group test objects by hyperspectral markers during external trajectory measurements

Ivan A. Kuleshov

Ministry of Defense RF, Military Unit 03080, Priozersk, Republic of Kazakhstan

ibnkuleshov@mail.ru, <https://orcid.org/0000-0002-8046-9065>

Abstract. The task of detecting elements of group flight test objects has been actualized. Its relevance is based on the growing need to provide external trajectory measurements when testing samples of advanced multi-agent systems, the elements of which are aircraft. An analysis was made of the existing algorithms for detecting objects used in modern optoelectronic stations. Based on the results of the analysis, it was concluded that these algorithms do not meet the requirements for testing group objects. As a problematic issue in their application is the complexity of the selection of objects against the atmospheric background. To ensure the detection of objects, it is proposed to use additional highly informative features that reflect the physical nature of the observed objects. Such features are the features of the shape of the spectrum of light reflected from various materials. In order to identify them, it is proposed to conduct a preliminary hyperspectral analysis of test objects with subsequent reduction in the data dimension. To eliminate errors that occur during rotation and partial overlap of objects, it was proposed to use neural network methods, in particular, the YOLO v2 neural network detector. A variant of data organization for its training is proposed, as well as a detector architecture that provides high accuracy and rate of information processing. These characteristics of the detector were confirmed experimentally on the basis of images exported from the model of the session of external trajectory measurements. A procedure for implementing neural network detection of group test objects was proposed. The results obtained are relevant for solving the issues of hardware and software for tracking optoelectronic systems.

Keywords: hyperspectral image, convolutional network, detector, group object, external trajectory measurements

Введение. Развитие технологий интеллектуальной обработки данных в последние годы сделало возможной физическую реализацию различных многоагентных систем.

Многоагентные системы представляют собой некоторое множество элементов, имеющих высокую автономность, действующих в едином информационном поле и способных




Рис. 1. Метод прямого отсчёта

Fig. 1. Direct count method

Вероятность правильного детектирования

Облачность	P_1	P_1^7
Ясно	0,81	0,23
Кучевая	0,79	0,19
Слоистая	0,84	0,30
Перистая	0,84	0,30

самоорганизовываться для оптимального решения поставленной задачи. В качестве элементов (агентов) таких систем могут выступать различные робототехнические комплексы, в частности беспилотные летательные аппараты (БПЛА) [1]. Многоагентные системы, особенно с роевой организацией, имеют множество применений как в мирных, так и в военных целях. Последний вариант в настоящее время получил наибольшую популярность, что подтверждается многочисленными пресс-релизами и заявлениями различных зарубежных исследовательских организаций. В частности, в США это программы OFFSET (OFFSET Envisions Swarm Capabilities for Small Urban Ground Units: [сайт]. URL: <https://www.darpa.mil/news-events/2016-12-07>) и Gremlins (Gremlins: [сайт]. URL: <https://www.darpa.mil/program/gremlins>) разработки DARPA, а также программа Locust (LOCUST: Autonomous, swarming UAVs fly into the future: [сайт]. URL: <https://www.onr.navy.mil/Media-Center/Press-Releases/2015/LOCUST-low-cost-UAV-swarm-ONR.aspx>) от ONR, в Китае – Swarm («Рой» беспилотников. Новая тактика боевых действий уникального оружия Китая: [сайт]. URL: <https://tass.ru/armiya-i-opk/5786857>) компании Norinco. Кроме того,

известен случай реального боевого применения Израилем в секторе Газа группы БПЛА с роевой организацией, однако до сих пор в открытых источниках нет информации ни о названии данной системы, ни о её производителе (Israel used world's first AI-guided combat drone swarm in Gaza attacks: [сайт]. URL: <https://www.newscientist.com/article/2282656-israel-used-worlds-first-ai-guided-combat-drone-swarm-in-gaza-attacks/>).

Тем не менее, независимо от целевого предназначения, неотъемлемой частью разработки подобных многоагентных систем являются лётные испытания разного уровня. При этом данные системы представляют собой групповые объекты испытаний (ГОИ), т. е. множество опытных образцов изделий, которые в процессе испытаний функционируют и наблюдаются одновременно.

Целью данной статьи является разработка практических предложений по обеспечению детектирования элементов групповых объектов лётных испытаний для решения задачи внешнетраекторных измерений.

Метод прямого отсчёта. При внешнетраекторных измерениях в ходе лётных испытаний используются снимки объекта, формируемые высокоточными оптико-электронными системами методом прямого отсчёта. Результат работы метода при измерении угла места ГОИ показан на рис. 1. Оптико-электронная система состоит из линзы L с фокусным расстоянием f и расположенного в её фокальной плоскости фотозлемента $\Phi Э$. Оптическая ось $C'C$ проходит через центр линзы и пересекает плоскость фотозлемента в его центре. Угол места оптической оси ϵ_d отсчитывается при помощи датчика положения $ДП$, установленного на горизонтальном валу опорно-поворотного устройства. Действительные значения углов места для каждого летательного аппарата (ЛА) вычисляются как разница $\Delta \epsilon$ между ϵ_d и положением его изображения $ЛА'$.

В ходе сеанса съёмки необходимо совмещать оптическую ось с геометрическим центром (так называемым центроидом) группы ЛА путём вращения вала. Для этого необходимо провести детектирование объектов с помощью детектора $ДО$ по изображениям, формируемым на фотозлементах $\Phi Э$, и по полученным точкам вычислить в решающем устройстве $РУ$ разность между угловым положением центроида и текущим положением оси. Эта разность передаётся в исполнительный механизм $ИМ$ для отработки. Совокупность блоков $ДО$, $РУ$, $ДП$ и $ИМ$ составляет систему наведения $СН$.

Важно, чтобы объект полностью присутствовал в кадре во время всего сеанса, в противном случае измерительная информация может быть потеряна или искажена. Другими словами, требуется оперативное и качественное детектирование элементов ГОИ.

Алгоритмы детектирования. Поскольку при съёмке ГОИ в кадре находится большое количество ЛА, то с точки зрения наблюдателя каждый ЛА будет малоразмерным объектом. Существуют различные алгоритмы детектирования таких объектов, реализованные в современных оптико-электронных системах [2, 3]. Они основаны на внутрикадровом анализе сигналов различных точек и их окрестностей

в инфракрасном и видимом диапазонах спектра. Характерным недостатком алгоритма [2] является достаточно низкая вероятность P правильного детектирования при достаточно высоком отношении сигнал/шум (здесь шум – уровень флуктуаций формируемого изображения из-за особенностей применяемых датчиков и неидеальности канала передачи данных). В таблице представлены значения вероятности в зависимости от типа облачности, где P_1 , P_1^7 – вероятности правильного детектирования одиночного объекта, указанные в работе [2], и ГОИ из семи объектов соответственно.

Алгоритм, описанный в [3], также неприменим для ГОИ, поскольку стробы поиска объектов, получаемые в результате децимации исходного изображения, достаточно обширны и при нахождении в кадре большого числа элементов могут захватывать и их. Такая децимация происходит в результате визуального увеличения наблюдаемого объекта за счёт появления вблизи него фоновых неоднородностей (например, в виде облачности). Таким образом, дополнительно встаёт вопрос о возможности использования указанного алгоритма при различных атмосферных явлениях, искажающих фон.

Также распространены алгоритмы, работа которых основывается на межкадровом смещении изображения объекта относительно фона (разностные алгоритмы) [4, 5]. Несмотря на то, что есть примеры их удачного применения в условиях достаточно сложного статического неоднородного фона, малейшая фоновая динамика приводит к образованию ложных меток. Устранение недостатков разностных алгоритмов за счёт внедрения корреляционных анализаторов сдвига рассмотрено в [6]. В определённые моменты времени или при достижении определённого порога рассогласования создаются и запоминаются эталонные кадры, относительно которых сдвиг анализируется далее. В результате такой алгоритм даёт хорошие результаты фильтрации фонового изображения, однако применять его целесообразно при съёмке одиночных объектов. Если в кадре будет множество аэродинамических объектов, часть из них может совершать движение, характерное для сдвигаемой области, что приведёт к ложной классификации их в качестве фона.

Одним из вариантов решения указанных проблем может стать использование дополнительных высокоинформативных сведений о физической природе наблюдаемых объектов. Эти сведения можно получить при анализе спектра отражённого от объектов света.

Гиперспектральные снимки. Гиперспектральные изображения, в отличие от трёхканальных RGB-изображений (RGB – red, green, blue), содержат мультиспектральные изображения из 10–15 каналов, каждый из которых состоит из нескольких сотен узкополосных фильтров 5–10 нм. Такая плотность фильтрации позволяет составлять квазинепрерывный спектр оптического сигнала, излучённого объектом. Различные материалы по-разному отражают и поглощают световое излучение, что проявляется в различной форме их спектральной плотности энергетической яркости (СПЭЯ) [7]. Другими словами, по гиперспектральному изображению какого-либо объекта можно достоверно предположить материалы,

входящие в его состав. Поэтому гиперспектральная визуализация уже применяется в различных областях промышленности, фармацевтике, пищевой отрасли и даже при дистанционном зондировании Земли. В качестве примера можно привести результаты спектроскопии искусственных материалов, взятые из библиотеки лаборатории ECOSTRESS (ECOSTRESS Spectral Library: [сайт]. <https://speclib.jpl.nasa.gov/download>) и сведённые на рис. 2.

Отражательная и поглощательная способности материала различаются, разные материалы имеют специфические формы спектра, что позволяет маркировать элементы ГОИ по материалам, из которых изготовлены объекты. Кроме того, если в составе группы имеются объекты узкоспециального назначения, то целесообразно выявить материалы, характерные для ЛА данного типа. Таким образом, создаются предпосылки либо для индивидуального детектирования, либо выделения подгрупп ЛА по целевому предназначению.

К негативным факторам, влияющим на формирование спектра отражённого сигнала, в первую очередь относится освещённость объекта: спектр излучаемого света и угол падения лучей. Спектр солнечного света может изменяться в зависимости от текущих свойств атмосферы и погодных условий, что приводит к изменению формы и пиковых значений СПЭЯ. Так как ЛА движется в атмосфере, совершая вращение вокруг трёх осей связанной системы координат, то освещаемая площадь будет каждый раз разной, как разная будет и энергия отражённой волны. В этой же связи возможны эффекты затенения элементами планера. Для устранения влияния этих факторов используются методы атмосферной коррекции, например, метод, предложенный в [8] и не требующий никакой дополнительной априорной информации об известных спектральных профилях или эталонных спектрах.

Гиперспектральное изображение представляет собой достаточно объёмный куб данных, поэтому обработка его целиком




Рис. 2. Спектры искусственных материалов – алюминия (1), стекла (2), меди (3), оливковой краски однослойной (4) и двухслойной (5), оцинкованной стали (6)

Fig. 2. Spectra of manmade materials: 1 – aluminum; 2 – glass; 3 – copper; 4, 5 – one and double coat of olive paint; 6 – galvanized steel

может потребовать значительных вычислительных мощностей. С целью сокращения размерности анализируемого гиперспектрального изображения можно воспользоваться некоторыми хорошо зарекомендовавшими себя методами, в частности блочным методом главных компонент [9].

Таким образом, по результатам гиперспектрального анализа можно получить набор уровней СПЭЯ в характерных поддиапазонах, которые показывают положение ЛА. Однако просто отслеживать межкадровое смещение областей с характерными формами СПЭЯ недостаточно, поскольку ЛА является сложным и динамическим объектом, вероятно, частично перекрываемым другими объектами группы. В этой связи имеет смысл рассмотреть возможность применения нейросетевых детекторов. К наиболее перспективным нейросетевым детекторам относятся свёрточные нейронные сети (СНС) различной архитектуры.

Свёрточная нейронная сеть. СНС строится на основе достаточно простой в плане вычислений операции. Входное изображение скалярно перемножается по частям на некоторую малоразмерную (как правило, размером не более 7×7) матрицу, т. е. каждый элемент области, покрываемой этой матрицей (ядром свёртки), перемножается на соответствующий элемент ядра, а полученные значения суммируются. Собственно, каждое ядро, а их может быть достаточно много, представляет собой какой-либо признак объекта. Часть ядер легко интерпретируется (например, ядра поиска углов или наклонных линий), но большинство сложно поддаются описанию на понятийном уровне.

Результаты свёртки образуют элементы выходной матрицы – карты признаков, которая в дальнейшем поступает на следующий свёрточный слой и так далее, пока количество признаков не станет исчерпывающим, а размерность – достаточно малой для последнего обучаемого слоя. В общем случае последний слой является полносвязным и предназначен для вероятностной оценки соответствия входных данных какому-либо классу.

Понижение размерности выходных данных достигается за счёт увеличения шага свёртки, а также применения субдискретизации (пулинга). Таким образом, в последний, полносвязный слой, предназначенный для выделения класса объекта, передаётся карта признаков небольшого размера, иногда сжатая до вектора.

СНС обладает рядом полезных в компьютерном зрении свойств [10]: инвариантностью к расположению признаков, что позволяет детектировать объекты по всему изображению; устойчивостью к геометрическим искажениям, которая

значительно повышает предсказательную способность (способность правильно классифицировать данные, ранее не использовавшиеся в обучении); минимальными вычислительными затратами за счёт сокращения числа весов; высоким темпом обработки входной информации, крайне необходимым в системах реального времени.

Среди различных архитектур свёрточных детекторов особенно выделяются YOLO v2, YOLO v3 [11, 12]. Их отличительной особенностью является однократное детектирование, буквально следующее из названия (*you only look once* – ты посмотришь только раз). При этом детектор с архитектурой YOLO v3 обладает более высокими показателями обнаружения объектов, существенно изменяющихся в масштабе. Естественно, что такой положительный эффект сильно сказывается на размерах сети: начинается распараллеливание ветвей свёртки с выводом классификации на каждой градации масштаба. Учитывая, что входные данные для эксперимента по обнаружению не предполагают сильного изменения размера наблюдаемых объектов, автором настоящей статьи принято решение взять за основу детектор YOLO v2.

Экспериментальное обучение нейросетевого детектора. Эксперименты по обучению нейросетевого детектора обнаружению ЛА проводились на базе пакета прикладных программ Matlab версии 2019b. Приложение Deep Networks Designer, входящее в состав данного программного обеспечения, позволяет быстро создавать сеть практически любой сложности, а инструмент Analyze помогает на ходу проверить работоспособность архитектуры и число обучаемых элементов при настройке гиперпараметров – параметров, не оптимизируемых в процессе обучения сети.

Также в Matlab последних версий уже имеются готовые алгоритмы обучения нейросетевых детекторов, в частности `trainYOLOv2ObjectDetector`, который обрабатывает все необходимые условия: тип алгоритма оптимизации (solver); размер обучающих выборок; L2-регуляризацию; число эпох; градацию скорости обучения и т. д. Кроме того, начиная с версии 2019b, появилась возможность комбинировать специфические наборы данных и аугментировать их для обучения YOLO-сетей.

Предварительное обучение. Для предварительного обучения сети типа YOLO создаётся СНС, предназначенная для детектирования одиночных объектов в выборке данных малого разрешения [13]. Другими словами, это свёрточная сеть произвольной архитектуры, основная цель которой – научиться выделять существенные признаки одиночных объектов на небольшом изображении.

Предварительная тренировка СНС обеспечивает более достоверный результат тренировки YOLO и значительно ускоряет сходимость к нему. Подобный эффект достигается за счёт того, что предварительно натренированная сеть, включенная в состав YOLO, уже способна достоверно классифицировать объекты, которые могут содержаться в пределах ограничивающей рамки (bounding box, bbox).

В качестве базы данных для предварительной тренировки выбраны снимки БПЛА на фоне высокой облачности под разными ракурсами в количестве 72 на каждый аппарат (в общей сложности 504 снимка одиночных БПЛА). Ввиду




Рис. 3. Примеры входных изображений

Fig. 3. Examples of input images

того, что стандартные алгоритмы обучения не рассчитаны на мультиспектральные изображения, каждый снимок определённым образом закодирован на трёх RGB-каналах: R- и B-каналы представлены встречным кодированием области характерных форм СПЭЯ, в G-канале размещено изображение видимого диапазона в оттенках серого цвета. Встречное кодирование в данном случае означает, что диапазоны значений R- и B-каналов поделены на равные части по количеству детектируемых элементов. При этом ступенчатое нарастание значений R соответствует пропорциональному уменьшению значений B, чем достигается максимальный контраст между объектами.

Примеры изображений из обучающей выборки представлены на рис. 3. СНС, использованная для предварительного обучения, представляет собой тройную последовательность слоёв «свёртка – нелинейность – нормализация» с одним полносвязным слоем в конце для выделения семи классов. Для сокращения размерности карт признаков каждая свёртка взята с двойным шагом. Первая ступень последовательности представляет собой три параллельные ветви указанной последовательности, объединённые в глубину, с ядрами свёртки размерами 1×1, 3×3 и 5×5 по восемь фильтров в каждой свёртке. На второй и третьей ступени используются по 50 фильтров 3×3. Входной слой представляет матрицу 80×80×3, что соответствует максимальному размеру элемента на общем снимке группы. В качестве алгоритма оптимизации выбран Adam ввиду хорошей устойчивости обучения и высокой скорости сходимости. Генеральная совокупность изображений разделена на обучающую и тестовую выборки объёмами соответственно 70 и 30 %.

После 50 эпох обучения точность классификации тестовой выборки составила 99,8 %. Такое высокое качество классификации обеспечено путём применения батч-нормализации перед каждой новой свёрткой и слоя активации с усечённым линейным преобразованием (rectified linear units, ReLU) в качестве нелинейности, а также аугментации входных данных.

Тренировка YOLO v2. Набор данных для обучения нейронных сетей типа YOLO состоит из двух компонентов: изображений, содержащих детектируемые объекты; ограничивающих рамок, в пределах которых они находятся, – так называемых аннотаций. Реальные изображения полёта группы БПЛА отсутствуют в открытом доступе, поэтому движение и внешний вид группы смоделированы [14]. При этом за основу взят внешний вид реальных образцов аппаратов отечественной разработки: С-70 «Охотник», «Дозор-600» и «Орлан-10». Полученные изображения перекодированы аналогично изображениям для предварительного обучения. Таким образом, обучающая выборка составила 1000 изображений разрешением 800×600 пикселей.

Ограничивающие рамки для обучения размечены вручную, что заняло длительное время. Для ускорения этого процесса использовано приложение Image Labeler из пакета Matlab.

В качестве «надстройки» к предварительно обученной сети подключён слой свёртки 1×1 с 96 фильтрами, а также специальные YOLO-слои трансформации и классификации. Итоговая архитектура нейросетевого детектора представлена на рис. 4.

При прохождении нескольких слоев свёртки с неединичным шагом уменьшается размерность карт признаков, что приводит к неизбежной потере информации об относительно мелких деталях исходного изображения. Для того чтобы исключить влияние этих потерь, предварительно обученная сеть параллельно подаёт данные первой свёрточной группы в специальный слой YOLO-реорганизации. Здесь происходит перестройка входных карт признаков под размер выхода последней свёртки предварительного обучения сети с их дальнейшим соединением в глубину.

В последней свёртке число N карт, или число каналов, задаётся исходя из условия

$$N = K(5 + C),$$

где K – число якорных рамок (anchor box); C – число классов; число 5 является количеством параметров для каждого




Рис. 4. Архитектура нейросетевого детектора

Fig. 4. Neural network detector architecture

предсказанного bbox – две координаты центра, его высота и ширина, а также оценка вероятности нахождения объекта внутри рамки (confidence score).

Якорные рамки представляют собой области, в пределах которых может наблюдаться объект. Каждая такая рамка несколько раз накладывается на предварительно размеченные ячейки изображения (grid cells), после чего лишние исключаются, исходя из метрики Intersection over Union (IoU):

$$IoU = \frac{B_1 \cap B_2}{B_1 \cup B_2},$$

где B_1 ; B_2 – якорные рамки.

Для удобства выбора размера и количества anchor box в Matlab, начиная с версии 2019b, реализована функция estimateAnchorBoxes, основанная на методе k -средних для метрики IoU. В представленном детекторе слой YOLO-трансформации содержит восемь якорных боксов, что дает среднее IoU=0,841.

Слои YOLO-трансформации и выхода последовательно реализуют функции предсказания положения и размеров ограничивающих рамок, в конечном счёте выделяя области, имеющие confidence score выше порогового уровня, и присваивая им соответствующий класс.

Тестовая (по которой осуществлялась настройка гиперпараметров) и валидационная выборки были сгенерированы отдельно и составили 610 и 1000 изображений соответственно. В результате 1000 эпох обучения точность детектирования сети на тестовой и валидационной выборках составила соответственно $(94,38 \pm 0,64)$ и $(92,94 \pm 0,61) \%$; $P=0,95$. Специфика работы YOLO-детектора такова, что каждый объект можно распознать несколько раз с высокой степенью достоверности при разных комбинациях anchor box, поэтому к итоговому результату применена фильтрация дубликатов по максимальному правдоподобию.

Результат работы детектора с кадром валидационной выборки представлен на рис. 5.




Рис. 5. Детектированный кадр

Fig. 5. Detected frame

Так как данная сеть рассчитана на детектирование объектов оптико-электронной системой в реальном масштабе времени, немаловажным параметром её работы является скорость обработки информации. Время детектирования валидационной выборки с последующим отсеиванием дубликатов составило 30,15 с, скорость 33,16 кадр/с. При этом вычисления производились на процессоре Intel Core i5-9300H (2,4 ГГц) в однопоточном режиме.

Предложения по практической реализации. Реализация нейросетевого детектирования по гиперспектральным маркерам при подготовке к испытаниям (первые пять этапов) и при их проведении (последние четыре этапа) включает следующие этапы:

- гиперспектральный анализ элементов, входящих в состав испытываемой многоагентной системы;

- поиск уникальных спектров или уникального расположения материалов;

- определение поддиапазонов длин волн, в которых проявляются характерные особенности формы СПЭЯ;

- настройка программы анализа по уровням СПЭЯ в указанных поддиапазонах;

- обучение нейросетевого детектора;

- передача изображений для анализа спектра и маркировки;

- конвертация изображений в RGB-систему по выставленным маркерам;

- нейросетевое детектирование;

- передача координат положения объектов для вычисления центроида группы.

В качестве основного ограничения выступает уровень освещённости объектов, поэтому применять описанный подход целесообразно только в дневных условиях.

Аппаратно-программная реализация нейросетевого детектирования при проведении испытаний возможна на автоматизированном рабочем месте оператора оптико-электронной системы. При этом программа маркировки и конвертации может быть выполнена на любом языке программирования, а свёрточная нейросеть может быть развернута как с использованием стандартного оборудования ПЭВМ (при помощи библиотек OpenCV для C/C++, Python, Java и т. д.), так и на специальных нейропроцессорах. К последним относятся тензорные процессоры типа Google TPU или Intel Nervana NNP, а также процессоры машинного зрения, например, Intel Movidius Myriad 2 или Mobileye EyeQ.

Заключение. По итогам анализа используемых в современных высокоточных оптико-электронных системах алгоритмов детектирования объектов испытаний выявлены проблемные вопросы, возникающие при появлении нового, группового объекта. Для их решения предложен метод гиперспектральной маркировки объектов испытаний. Предложенная архитектура нейросетевого детектора типа YOLO позволяет оперативно и качественно обрабатывать формируемые изображения. Для обеспечения работы алгоритмов обучения и работы детектора рекомендовано конвертировать гиперспектральные изображения в трёхцветные.

Высокая скорость обработки данных достигается за счёт малой глубины архитектуры и поэтапного сокращения размерности карт признаков операцией свёртки с шагом. Высокая точность детектирования $(92,94 \pm 0,61) \%$ достигнута благодаря качественной предварительной тренировке.

В итоге проведённой работы определён порядок реализации нейросетевого детектирования при подготовке и проведении испытаний. Основным ограничением применимости гиперспектральной разметки является требование достаточной освещённости, поэтому целесообразно использовать такой подход только в дневное время суток.

Полученные результаты можно использовать при разработке оптико-электронных систем внешнетраекторных измерений с автоматическим детектированием и сопровождением групповых объектов лётных испытаний.

Список источников

1. Городецкий В. И., Карсаев О. В., Самойлов В. В., Серебряков С. В. Прикладные многоагентные системы группового управления // Искусственный интеллект и принятие решений. 2010. № 5. С. 301–317. <https://doi.org/10.3103/S0147688210050060>
2. Набатчиков А. С., Якименко И. В. Способ обнаружения малоразмерных тепловых объектов на атмосферном фоне // Математическая морфология. 2012. Т. 11. № 4. URL: <http://sgma.alpha-design.ru/MMORPH/N-36-html/nabatchikov/nabatchikov.htm> (дата обращения: 09.02.2022 г.).
3. Бабаян П. В., Фельман А. Б. Обнаружение и оценка параметров воздушных объектов в видеопоследовательностях на основе кратномасштабной пространственной обработки // Цифровая обработка сигналов. 2010. № 4. С. 7–11.
4. Ваниев А. А., Емельянов Г. М. Метод выделения быстро движущихся объектов при использовании цифрового оптического локатора следящего типа // Компьютерная оптика. 2013. Т. 37. № 4. С. 477–483. <https://doi.org/10.18287/0134-2452-2013-37-4-477-483>
5. Кочкин В. А. Автоматическое выделение динамических объектов на фоне подстилающей поверхности // Наука и образование: научное издание МГТУ им. Н. Э. Баумана. 2014. № 12. С. 889–902. <https://doi.org/10.7463/1214.0749279>
6. Суровцев П. Ю., Суслин А. С. Корреляционно-разностный алгоритм обнаружения воздушных объектов, наблюдаемых на фоне неоднородного неба // Труды МАИ. 2018. № 103. С. 16.
7. Barnabe P., Dislaire G., Leroy S., Pirard E., *Journal of Electronic Imaging*, 2015, no. 24, 061115. <https://doi.org/10.1117/1.JEI.24.6.061115>
8. Денисова А. Ю., Мясников В. В. Атмосферная коррекция гиперспектральных изображений с использованием верифицированных данных малого объема // Компьютерная оптика. 2016. Т. 40. № 4. С. 526–534. <https://doi.org/10.18287/2412-6179-2016-40-4-526-534>
9. Пестунов И. А., Мельников П. В. Метод главных компонент и его модификации в задачах классификации гиперспектральных данных // Интерэкспо ГЕО-Сибирь. 2015. Т. 4. № 2. С. 45–50.
10. Goodfellow I., Bengio Y., Courville A., *Deep Learning*, MIT Press, 2016, 800 p.
11. Redmon J., Farhadi A., *YOLOv3: An Incremental Improvement*, 2018, <https://arxiv.org/abs/1804.02767v1> [cs.CV].

12. Redmon J., Farhadi A. *YOLO9000: Better, Faster, Stronger*, 2016, <https://arxiv.org/abs/1612.08242v1> [cs.CV].

13. Redmon J., Divvala S., Girshick R., Farhadi A., *You only look once: Unified, real-time object detection*, 2016, <https://arxiv.org/abs/1506.02640v5> [cs.CV].

14. Свидетельство о регистрации программы для ЭВМ №2020615926 / И. А. Кулешов. Модель сеанса мультиспектральных измерений траектории движения роя беспилотных летательных аппаратов.

References

1. Gorodetskii V. I., Karsaev O. V., Samoilov V. V., Serebryakov S. V., *Scientific and Technical Information Processing*, 2010, vol. 37 no. 5, pp. 301–317. (In Russ.) <https://doi.org/10.3103/S0147688210050060>
2. Nabatchikov A. S., Yakimenko I. V., *Matematicheskaya morfologiya*, 2012, no. 4, available at: <http://www.sci.rostelecom67.ru/user/sgma/MMORPH/N-36-html/nabatchikov/nabatchikov.htm> (accessed: 09.02.2022). (In Russ.)
3. Babayan P. V., Fel'dman A. B., *Tsifrovaya obrabotka signalov*, 2010, no. 4, pp. 7–11. (In Russ.)
4. Vaniev A. A., Emel'yanov G. M., *Computer optics*, 2013, vol. 37, no. 4, pp. 477–483. (In Russ.) <https://doi.org/10.18287/0134-2452-2013-37-4-477-483>
5. Kochkin V. A., *Science and Education of the Bauman MSTU*, 2014, no. 12, pp. 889–902. (In Russ.) <https://doi.org/10.7463/1214.0749279>
6. Surovtsev P. Yu., Suslin A. S., Correlation-difference algorithm for aerial objects detection observed against non-uniform sky background, *Trudy MAI*, 2018, no. 103, p. 16. (In Russ.)
7. Barnabe P., Dislaire G., Leroy S., Pirard E., *Journal of Electronic Imaging*, 2015, no. 24, 061115. <https://doi.org/10.1117/1.JEI.24.6.061115>
8. Denisova A. Yu., Myasnikov V. V., Atmospheric correction of hyperspectral images using small volume of the verified data, *Computer optics*, 2016, vol. 40, no. 4, pp. 526–534. (In Russ.) <https://doi.org/10.18287/2412-6179-2016-40-4-526-534>
9. Pestunov I. A., Mel'nikov P. V., Principal component analysis and its modifications in hyperspectral image classification, *Interexpo GEO-Siberia*, 2015, vol. 4, no. 2, pp. 45–50. (In Russ.)
10. Goodfellow I., Bengio Y., Courville A., *Deep Learning*, MIT Press, 2016, 800 p.
11. Redmon J., Farhadi A., *YOLOv3: An Incremental Improvement*, 2018, <https://arxiv.org/abs/1804.02767v1> [cs.CV].
12. Redmon J., Farhadi A., *YOLO9000: Better, Faster, Stronger*, 2016, <https://arxiv.org/abs/1612.08242v1> [cs.CV].
13. Redmon J., Divvala S., Girshick R., Farhadi A., *You only look once: Unified, real-time object detection*, 2016, <https://arxiv.org/abs/1506.02640v5> [cs.CV].
14. Certificate of registration of a computer program № 2020615926, 4.06.2020, I. A. Kuleshov.

Статья поступила в редакцию 02.02.2022; одобрена после рецензирования 16.02.2022; принята к публикации 17.02.2022. The article was submitted 02.02.2022; approved after reviewing 16.02.2022; accepted for publication 17.02.2022.