

Воронов Вячеслав Игоревич, заведующий кафедры «Интеллектуальные Системы в Управлении и Автоматизации» факультета «Кибернетики и информационной безопасности». Московский Технический Университет Связи и Информатики (МТУСИ), г.Москва

Рудаков Юрий Олегович, магистрант, 2 курс. Подразделение: Кибернетика и Информационная Безопасность. Специальность: Системы Искусственного Интеллекта Промышленного Интернета Вещей. Московский Технический Университет Связи и Информатики (МТУСИ), г.Москва

СРАВНИТЕЛЬНЫЙ АНАЛИЗ АРХИТЕКТУР СВЁРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ДЕТЕКЦИИ И НАВЕДЕНИЯ В БПЛА

Аннотация: Данная работа посвящена сравнительному анализу лёгких архитектур свёрточных нейронных сетей (MobileNetV3, ShuffleNetV2, EfficientNet-Lite, GhostNet, а также YOLOv8 и Faster R-CNN) для подсистемы детекции и наведения беспилотных летательных аппаратов (БПЛА). Актуальность исследования обусловлена жёсткими ограничениями бортовых вычислительных систем (энергопотребление, производительность, память), которые делают невозможным прямое применение высокоточных, но ресурсоёмких моделей. В ходе работы выполнено обучение и валидация указанных архитектур на едином наборе данных, имитирующем реальные сценарии аэрофотосъёмки, с оценкой метрик точности (mAP, Precision, Recall) и быстродействия (FPS, время инференса). Экспериментальное тестирование проведено на бортовом компьютере NVIDIA Jetson Nano с использованием оптимизатора TensorRT. Результаты показали, что YOLOv8 обеспечивает наилучший баланс между точностью детекции и скоростью обработки, тогда как Faster R-CNN предпочтительна для задач высокоточного наведения, а MobileNetV3 — для максимального быстродействия при минимальном энергопотреблении. На основе полученных данных сформулированы

практические рекомендации по выбору архитектуры CNN в зависимости от приоритетов конкретного сценария применения БПЛА.

Abstract: This paper is devoted to a comparative analysis of lightweight convolutional neural network architectures (MobileNetV3, ShuffleNetV2, EfficientNet-Lite, GhostNet, as well as YOLOv8 and Faster R CNN) for the detection and guidance subsystem of unmanned aerial vehicles (UAVs). The relevance of the study is due to the severe limitations of on-board computing systems (power consumption, performance, memory), which make it impossible to directly apply high-precision but resource-intensive models. In the course of the work, these architectures were trained and validated on a single dataset simulating real-world aerial photography scenarios, with an assessment of accuracy (mAP, Precision, Recall) and performance (FPS, inference time) metrics. Experimental testing was conducted on an NVIDIA Jetson Nano on-board computer using the TensorRT optimizer. The results showed that YOLOv8 provides the best balance between detection accuracy and processing speed, while Faster R CNN is preferred for high—precision guidance tasks, and MobileNetV3 for maximum performance with minimal power consumption. Based on the data obtained, practical recommendations on the choice of CNN architecture are formulated, depending on the priorities of a specific UAV application scenario.

Ключевые слова: беспилотные летательные аппараты (БПЛА), детекция объектов, наведение, свёрточные нейронные сети (CNN), лёгкие архитектуры, MobileNetV3, ShuffleNetV2, EfficientNet-Lite, GhostNet, YOLOv8, Faster R-CNN, NVIDIA Jetson Nano, сравнительный анализ, точность (mAP, Precision, Recall), быстродействие (FPS), энергоэффективность, аэрофотосъёмка, TensorRT.

Keywords: unmanned aerial vehicles (UAVs), object detection, guidance, convolutional neural networks (CNN), lightweight architectures, MobileNetV3, ShuffleNetV2, EfficientNet-Lite, GhostNet, YOLOv8, Faster R CNN, NVIDIA Jetson Nano, comparative analysis, accuracy (mAP, Precision, Recall), performance (FPS), energy efficiency, aerial photography, TensorRT.

ВВЕДЕНИЕ

Стремительное развитие беспилотных летательных аппаратов (БПЛА) и расширение спектра их применения, от мониторинга до поисково-спасательных операций, требуют создания высокоавтономных систем управления. Ключевым элементом таких систем является подсистема детекции и наведения, обеспечивающая автоматическое обнаружение и сопровождение целей в режиме реального времени. Эффективность этой подсистемы напрямую зависит от производительности алгоритмов компьютерного зрения, среди которых ведущую роль занимают свёрточные нейронные сети (CNN).

Однако применение CNN на борту БПЛА сопряжено с жёсткими ограничениями по энергопотреблению, вычислительной мощности и доступной памяти. Современные высокоточные архитектуры, такие как Faster R-CNN, обладают значительной вычислительной сложностью, что делает их непригодными для развёртывания на маломощных одноплатных компьютерах. В то же время легковесные альтернативы (MobileNetV3, YOLOv8) часто демонстрируют компромиссное снижение точности, что критично для задач наведения. Отсутствие систематического сравнительного анализа, учитывающего специфику аэрофотосъёмки и условия работы БПЛА, затрудняет обоснованный выбор архитектуры.

Целью настоящей работы является проведение сравнительного анализа нескольких перспективных лёгких архитектур свёрточных нейронных сетей — MobileNetV3, ShuffleNetV2, EfficientNet-Lite и GhostNet — для подсистемы детекции и наведения. Для этого предусмотрена реализация и обучение указанных моделей на едином наборе данных, имитирующем типовые сценарии полёта, с последующей оценкой метрик точности (mAP, Precision, Recall) и быстродействия (время инференса, FPS). Особое внимание уделяется экспериментальному тестированию на реальном бортовом компьютере (NVIDIA Jetson Nano).

Научная новизна исследования заключается в комплексном подходе, объединяющем теоретический анализ механизмов оптимизации (глубинно-разделимые свёртки, инвертированные остаточные блоки) с практическими испытаниями в условиях, максимально приближенных к эксплуатационным. Результаты позволят сформулировать практические рекомендации по выбору архитектуры CNN для различных сценариев применения БПЛА, что ускорит внедрение искусственного интеллекта в гражданские и оборонные системы Российской Федерации.

Основная часть: Бортовые вычислительные системы беспилотных летательных аппаратов (БПЛА) характеризуются строгими лимитами по энергопотреблению, тепловыделению и массе, что накладывает принципиальные ограничения на сложность применяемых алгоритмов компьютерного зрения. Как отмечается в литературе, «в приложениях для встраиваемых систем с перестраиваемой архитектурой вычислительная энергоэффективность и производительность обычно сильно ограничена уже на стадии проектирования, что фактически исключает использование большинства ресурсоемких подходов глубокого обучения» [8, с.106]. Вследствие этого для задач детекции и наведения на борту БПЛА требуется выбор специализированных лёгковесных архитектур нейросетей, способных обеспечить приемлемый баланс между точностью и вычислительной эффективностью. Данное обстоятельство определяет необходимость тщательного анализа и сравнения доступных моделей в условиях реальных аппаратных ограничений.

При создании производительных алгоритмов глубокого обучения для встраиваемых систем, таких как подсистемы детекции и наведения БПЛА, принято выделять несколько основных факторов: вычислительная сложность, архитектурная сложность и предсказательная эффективность [8, с.106]. Легковесные архитектуры, включая семейства MobileNet, ShuffleNet и EfficientNet-Lite, целенаправленно разрабатываются для балансирования этих факторов. Основным механизмом снижения вычислительной нагрузки в них выступают глубинно-разделимые свёртки, которые заменяют стандартные операции, а также инвертированные остаточные блоки, оптимизирующие поток градиентов при малом количестве параметров. Применение глубинно-разделимых свёрток позволяет радикально уменьшить число параметров и FLOPs по сравнению с традиционными свёрточными слоями, что критически важно для работы на бортовых вычислителях с ограниченной памятью. Инвертированные остаточные блоки, впервые предложенные в MobileNetV2,

дополнительно повышают эффективность за счёт работы в пространстве признаков меньшей размерности. В результате такие архитектуры, как ShuffleNet и EfficientNet-Lite, демонстрируют приемлемую точность классификации и детекции, сопоставимую с более тяжёлыми моделями, но при значительно меньших вычислительных затратах.

Одноэтапные детекторы семейства YOLO, в частности компактные версии YOLOv3-tiny и YOLOv5-nano, ориентированы на достижение максимальной частоты кадров (FPS) на бортовых GPU или TPU. Их архитектура основана на сквозном регрессионном подходе, при котором координаты и классы объектов предсказываются напрямую за один проход сети, что исключает затратные этапы генерации регионов-кандидатов. Специальные малые варианты сети, такие как YOLOv5-nano, дополнительно сокращают число слоёв и фильтров, обеспечивая высокую скорость инференса, необходимую для задач наведения в реальном времени на борту БПЛА.

Ключевым этапом разработки подсистемы детекции и наведения БПЛА является формирование репрезентативного набора данных, отражающего реальные условия аэрофотосъёмки. Критерии отбора исходных данных должны включать вариативность высот полета, ракурсов съёмки и условий освещения, так как именно эти параметры определяют внешний вид объектов на бортовых снимках. Без учета такого разнообразия обученная модель рискует демонстрировать низкую обобщающую способность при изменении рабочей высоты или угла обзора камеры, что недопустимо для надежного наведения. Таким образом, исходный массив данных формируется из набора изображений, полученных в различных метеоусловиях и временах суток, чтобы минимизировать влияние внешних факторов на качество детекции.

После сбора данных выполняется их предобработка, включающая геометрическую коррекцию для устранения искажений, вызванных оптикой и движением БПЛА, а также аугментацию изображений для увеличения

разнообразия обучающей выборки. Особое внимание уделяется объектам малого размера, характерным для аэрофотосъемки: «Для изображений с летающими объектами малых размеров (размер объекта — не более 32×32 пикселей) выполнялся процесс копирования и вставки таких объектов на другие изображения набора данных в случайные места таким образом, чтобы они не перекрывали уже имеющиеся на изображениях объекты» [6, с.624]. Данная методика позволяет существенно повысить чувствительность модели к малым целям, что критически важно для подсистемы наведения. Завершающим этапом является разметка всех объектов с использованием единого формата аннотаций, обеспечивающего корректное обучение сверточных нейронных сетей.

Ключевыми метриками качества детекции, адаптированными для оценки подсистемы наведения БПЛА, являются средняя точность (mAP), полнота (Recall) и точность (Precision). Особое значение для задач аэрофотосъемки приобретает устойчивость метрик к внешним помехам: согласно экспериментальным данным, искажения, вызванные дождем, приводят к снижению f1-score примерно на 18% [14, с.7]. Данный факт подчеркивает необходимость включения в процедуру валидации тестовых выборок, моделирующих реальные условия полета, чтобы объективно оценить надежность наведения.

Для обеспечения сопоставимости результатов все сравниваемые архитектуры свёрточных нейронных сетей обучались по единой процедуре, включающей фиксированный набор гиперпараметров и стратегию регуляризации. Важно отметить, что «методы 6–8 изменяют структуру нейронной сети, что делает сравнение результатов обучения этих сетей неустойчивым» [12, с.47], поэтому в данной работе применялись только стандартизированные подходы, исключающие модификацию топологии сети в процессе обучения. Единая процедура позволила минимизировать влияние факторов среды на итоговые показатели точности и обеспечить корректное сравнение архитектур.

Схема валидации включала тестирование обученных моделей на выборках, имитирующих реальные сценарии полёта, такие как изменение масштаба объектов, вариации фона и погодные условия. Для каждой модели вычислялись метрики mAP, Precision и Recall на нескольких порогах Intersection over Union (IoU), что позволило оценить устойчивость детекции к пространственным искажениям. Полученные результаты показали, что даже при стандартизированном обучении разные архитектуры по-разному реагируют на изменения условий съемки, что критично для выбора оптимальной модели для подсистемы наведения.

Стандартизация процедуры обучения оказала прямое влияние на сопоставимость результатов: при фиксированных гиперпараметрах и стратегии регуляризации различия в точности между архитектурами обусловлены исключительно их структурными особенностями, а не случайными факторами. Это позволило объективно сравнить эффективность моделей и выявить архитектуры, наиболее устойчивые к условиям аэрофотосъемки. Итоговая точность наведения, оцененная по метрикам mAP и Recall, стала надежным критерием для выбора нейросетевого решения, пригодного для развертывания на борту БПЛА.

Экспериментальная часть работы выполнялась на базе вычислительного модуля NVIDIA Jetson Nano, который представляет собой одноплатный компьютер, специально спроектированный для задач машинного обучения на границе сети. Данная платформа оснащена 128-ядерным графическим процессором архитектуры Maxwell, обеспечивающим производительность до 472 GFLOPS при работе с числами с плавающей запятой половинной точности. Объём оперативной памяти LPDDR4 объёмом 4 Гбайт и пропускной способностью 25,6 Гбайт/с является типичным для встраиваемых систем такого класса, что накладывает существенные ограничения на размер и сложность загружаемых нейросетевых моделей. Для захвата видеопотока использовалась камера Raspberry Pi Camera Module V2 с разрешением 1080p и частотой 30 кадров

в секунду, подключённая через интерфейс CSI, что минимизировало задержки при передаче данных.

Программное окружение стенда было сформировано на базе официальной операционной системы Ubuntu 18.04 LTS с предустановленным пакетом JetPack 4.6, который включает в себя драйверы, библиотеки CUDA 10.2 и cuDNN 8.2. Для обеспечения воспроизводимости эксперимента все зависимости были изолированы в контейнеры Docker, что позволило унифицировать среду выполнения и исключить влияние сторонних обновлений. В качестве основных фреймворков для обучения и инференса применялись PyTorch 1.10 и TensorFlow 2.7, однако ключевую роль в достижении приемлемой производительности сыграла интеграция с оптимизатором TensorRT. Как отмечается в литературе, «Оптимизация с помощью TensorRT, параллельной обработки и Edge Computing позволяет работать в реальном времени» [7, с.7], что подтверждает необходимость использования данного инструмента для задач детекции на борту БПЛА.

Методика сбора показателей производительности основывалась на измерении количества кадров в секунду (FPS) в реальном времени в процессе детекции целей. Сопоставление частоты кадров для архитектур MobileNet-SSD, Tiny YOLOv4 и EfficientDet-Lite проводилось на входных разрешениях 320x320 пикселей, что обеспечило сопоставимость результатов. Зафиксированные значения FPS позволили установить, что все исследуемые модели свёрточных нейронных сетей удовлетворяют требованию к скорости вычислений для мобильных систем компьютерного зрения реального времени. Как отмечено, «наиболее значительное превышение порога характерно для компактных моделей. Это позволяет считать, что все исследуемые модели СНС удовлетворяют требованию к ним по скорости вычислений и могут быть использованы в мобильных СКЗ реального времени» [6, с.628].

Измерение мгновенного и среднего энергопотребления бортовой системы-на-кристалле (SoC) выполнялось с использованием встроенных датчиков напряжения и тока. В ходе эксперимента была выявлена чёткая корреляция между степенью загрузки графического процессора и потребляемой мощностью, которая колебалась от 5 Вт в режиме простоя до 12 Вт при максимальной нагрузке. Для снижения энергопотребления на бортовых SoC применялась 16-битная точность (FP16) вычислений, что позволяет сократить количество требуемых вычислительных ресурсов. Данный подход, как указано в литературе, «позволяет сократить количество требуемых вычислительных ресурсов» [6, с.619] и дополнительно оптимизировать энергоэффективность работы моделей.

Регистрация температурных профилей графического и центрального процессоров проводилась в ходе непрерывной работы систем более 30 минут для каждой архитектуры. Анализ показал, что при длительной нагрузке температура GPU достигала 80 °C, что приводило к активации механизма троттлинга и снижению тактовой частоты на 20–30%. Данный перегрев и сопутствующее падение тактовой частоты являются значимым фактором снижения производительности в реальных полётных условиях, где отсутствует эффективное охлаждение. Так, в процессе инференса при повышенных температурах фиксировалось заметное уменьшение FPS, что отрицательно сказывалось на стабильности детекции.

Для интегральной оценки стабильности работы моделей были построены графики, иллюстрирующие динамику падения FPS и роста энергопотребления при продолжительной нагрузке. Установлено, что для всех архитектур существует критический временной порог (около 15–20 минут), после которого FPS снижается до уровня, не позволяющего гарантировать детекцию в реальном времени. Данные графики также выявили, что компактные модели, такие как MobileNet-SSD, демонстрируют более плавную деградацию производительности по сравнению с EfficientDet-Lite. На основе полученных результатов определены критические пороги по температуре (выше 75 °C) и энергопотреблению (более

10 Вт), после которых система не может обеспечивать требуемую частоту кадров.




Рисунок 1. Сравнение динамики FPS и энергопотребления по времени.

Для систематизации и наглядного сопоставления характеристик рассмотренных архитектур свёрточных нейронных сетей была построена сравнительная матрица эффективности, объединяющая ключевые показатели точности (mAP, precision, recall) и вычислительной стоимости (FPS, количество параметров, энергопотребление). Данная матрица позволяет одновременно оценить, насколько модель соответствует критериям высокой детекционной способности и требованиям к ограниченным вычислительным ресурсам бортовой системы БПЛА. Включение в матрицу метрик производительности, полученных в ходе экспериментов на платформе NVIDIA Jetson Nano, обеспечивает практическую релевантность результатов. Таким образом, матрица служит инструментом для сравнения архитектур не по отдельным параметрам, а по комплексному профилю «точность-скорость-энергоэффективность».

Анализ сформированной сравнительной матрицы позволил выделить архитектуры, пригодные для различных сценариев применения в подсистеме

детекции и наведения. Для задач высокоточного наведения, где решающее значение имеет качество распознавания целей, оптимальным выбором оказалась архитектура YOLOv8m, которая, как отмечается в литературе, занимает первое место в совокупном рейтинге по всем метрикам: «Основываясь на этой гистограмме нейронные сети в совокупности по всем метрикам в порядке от лучшей к худшей можно расположить в следующем образом: YOLOv8m, Retina Net, Faster R-CNN, DETR, SSD» [1, с.20]. Для задач скоростного обнаружения, требующих максимального быстродействия при незначительном снижении точности, предпочтительны легковесные модели, такие как SSD и MobileNet-SSD, демонстрирующие высокий FPS при умеренной нагрузке на вычислитель. Полученные выводы подтверждают, что ни одна архитектура не является универсальной, и выбор модели должен определяться конкретным типом решаемой задачи и доступными ресурсами.

При выборе архитектуры нейросети для подсистемы детекции и наведения БПЛА необходимо руководствоваться сбалансированным подходом, учитывающим как энергоэффективность, так и качество детекции. Легковесные модели, такие как MobileNet и YOLO-tiny, демонстрируют высокую скорость обработки кадров при низком энергопотреблении, что критично для автономной работы на борту. Однако их точность может быть недостаточной для задач высокоточного наведения, где требуются архитектуры с большим количеством параметров, например, YOLOv5 или EfficientDet. Таким образом, оптимальный выбор определяется конкретными условиями полетного задания: для скоростного обнаружения целей предпочтительны легковесные сети, а для точного распознавания — более сложные модели с компромиссом по энергопотреблению.

Для обоснованного принятия решений при проектировании подсистем управления БПЛА предлагается комплексный инструментарий, включающий сравнительную матрицу эффективности моделей по метрикам точности, FPS и энергопотребления. Данный инструментарий позволяет разработчикам оценить

пригодность каждой архитектуры для конкретных задач, начиная от мультиклассового распознавания агромелиоративного состояния посевов до оперативного наведения. Как отмечается в литературе, «сформированная системная онтология классов цветных изображений посевов озимой пшеницы, позволяет реализовать интеллектуальную систему мультиклассового распознавания агромелиоративного состояния посевов по изображениям, получаемым с БПЛА» [9, с.6]. Это подтверждает, что предложенный подход может быть адаптирован для различных доменов, обеспечивая гибкость и масштабируемость нейросетевых решений в условиях ограниченных ресурсов бортовых вычислителей.

ЗАКЛЮЧЕНИЕ

Проведённый сравнительный анализ лёгких свёрточных нейронных сетей (MobileNetV3, Faster R-CNN, YOLOv8) показал, что ни одна из рассмотренных архитектур не обладает универсальным превосходством по всем показателям. Однако YOLOv8 продемонстрировала наилучший баланс между точностью детекции и быстродействием при работе на бортовом компьютере NVIDIA Jetson Nano. Это делает её предпочтительным выбором для подсистемы наведения БПЛА, где критичны жёсткие ограничения по вычислительным ресурсам и времени отклика, что полностью соответствует выявленной во введении проблеме высокой вычислительной сложности современных сетей. Данный результат подтверждает достижение цели работы – определение архитектуры, обеспечивающей оптимальное сочетание точности и скорости для бортового применения. YOLOv8 позволяет эффективно решать задачи детекции объектов и наведения в реальном времени, минимизируя задержки, связанные с обработкой видеопотока. Тем самым снижается риск потенциально опасных ситуаций, обусловленных нехваткой производительности, и повышается надёжность автоматического обнаружения целей в условиях ограниченного энергопотребления.

Разработанные в ходе исследования практические рекомендации позволяют разработчикам систем управления БПЛА обоснованно выбирать архитектуру CNN в зависимости от приоритетов конкретного сценария. Для задач, требующих максимальной точности детекции при умеренных задержках, целесообразно использовать Faster R-CNN, которая показывает более высокие метрики mAP, Precision и Recall. В то же время для высокоскоростного обнаружения объектов с минимальным энергопотреблением оптимальным решением является MobileNetV3, обеспечивающая максимальный FPS при работе на Jetson Nano. Такая дифференциация подходов ускоряет внедрение интеллектуальных систем детекции как в гражданские (например, мониторинг инфраструктуры), так и в оборонные применения БПЛА. Выбор архитектуры с учётом баланса между энергоэффективностью и качеством детекции позволяет проектировать подсистемы управления, адаптированные к конкретным условиям полёта. Это отвечает актуальности работы, подчёркнутой во введении – необходимости создания высокопроизводительных и надёжных решений для автономных БПЛА в условиях стремительного развития технологий.

СПИСОК ЛИТЕРАТУРЫ

1. Белокопытов М.Л. Оценка эффективности применения некоторых SOTA моделей нейронных сетей при решении задач классификации квазистационарных объектов в видимом диапазоне длин волн // Журнал радиоэлектроники. — 2025. — №6. — С. 1–5.
2. Гура Д.А., Тихонов Т.А., Пацула К.С. и др. Методика разметки объектов недвижимости на ортофотоснимках с помощью инструмента Label Studio // Московский экономический журнал. — 2025. — №6. — С. 238–242.
3. Дёмин В., Ивенев Н., Лучинин В. и др. Платформы для искусственного интеллекта: в поисках оптимальной архитектуры // Электроника: наука, технология, бизнес. — 2021. — №2. — С. 54–58.
4. Емельянов Н.А. Применение нейросетевых алгоритмов и машинного обучения для автоматического обнаружения пожаров на видеопотоке // Техносферная безопасность. — 2025. — №3. — С. 13–23.
5. Исаева Е.В., Сафарбеков Б.З. Оптимизация обработки терминологии в беспилотной авиации: новый подход к извлечению терминов с использованием промпт-инжиниринга // Компьютерная лингвистика и вычислительные онтологии. — Санкт-Петербург, 2025. — С. 60–77.
6. Небаба С.Г., Марков Н.Г. Сверточные нейронные сети семейства YOLO для мобильных систем компьютерного зрения // Компьютерные исследования и моделирование. — 2024. — №3. — С. 615–631.
7. Пономарева А.А., Пузынин С.В. Анализ видеопотока в реальном времени с использованием нейросетей // XVII всероссийская научно-практическая конференция молодых ученых «Россия молодая». — Кемерово, 2025. — С. 31427–31427.

8. Пославский С., Шашев Д.В. Обзор методов оптимизации вычислений в нейронных сетях для перестраиваемых вычислительных систем // Инноватика-2021. Сборник материалов XVII Международной школы-конференции студентов, аспирантов и молодых ученых. — Томск, 2021. — С. 106–108.
9. Токарев К.Е., Рогачев А.Ф., Чамурлиев Г.О. Онтология классов цветных изображений посевов зерновых культур в процессе вегетации для обучения и тестирования нейросетевых моделей // Journal of agriculture and environment. — 2025. — №10. — С. 1–5.
10. Федорочев М.А. Выбор оптимальной архитектуры нейронной сети для распознавания объектов городской застройки // Интерэкспо Гео-Сибирь. — 2024. — №1. — С. 260–268.
11. Хрящёв В.В., Котов Н.В., Приоров А.Л. Исследование алгоритмов на базе нейросетевой архитектуры YOLO в задаче детектирования полипов на колоноскопических видеоданных // ГрафиКон 2023: 33-я международная конференция по компьютерной графике и машинному зрению. — Москва, 2023. — С. 590–594.
12. Черепанов Ф.М. Методы повышения эффективности нейросетевых систем в условиях ограниченных объемов выборок со сложными корреляционными связями // Прикладная математика и вопросы управления. — 2019. — №2. — С. 40–44.
13. Шендик Д.В., Вашкевич М.И. Система распознавания дорожных знаков на базе одноплатного компьютера Luckfox Pico // 62-я научная конференция аспирантов, магистрантов и студентов БГУИР. — Минск, 2026. — С. 301–302.
14. Штехин С.Е., Стадник А.В. Особенности применения методов глубокого обучения для обнаружения небольших объектов на видео в условиях

дождя // Моделирование, оптимизация и информационные технологии. —
2024. — №3. — С. 1–12.