

УДК 004.8

Павлюк Даниил Артемович, обучающийся бакалавриата, Казанский национальный исследовательский технический университет им. А.Н. Туполева – КАИ, г. Казань

Pavlyuk Daniil Artemovich, Undergraduate Student, Kazan National Research Technical University named after A. N. Tupolev – KAI, Kazan

e-mail: liketoeatpizza19@gmail.com

ПРИМЕНЕНИЕ НЕЙРОСЕТЕВЫХ МОДЕЛЕЙ В ГИС ДЛЯ РАСПОЗНАВАНИЯ ОБЪЕКТОВ НА МЕСТНОСТИ

Аннотация. Статья посвящена применению нейросетевых моделей в геоинформационных системах (ГИС) для автоматизации процесса распознавания объектов на местности по данным аэрофотосъемки. Рассматриваются недостатки ручной обработки материалов, такие как высокая стоимость, низкая производительность и риск ошибок, а также преимущества внедрения искусственного интеллекта (ИИ). Авторы анализируют различные архитектуры сверточных нейронных сетей (CNN), включая R-CNN, YOLO, SSD, и специализированные подходы, например, DFL-CNN, для решения задач детектирования объектов на аэрокосмических снимках со сложными условиями. Обсуждается использование современных фреймворков (PyTorch, TensorFlow) и специализированных библиотек (Raster Vision, TorchGeo) для разработки и обучения моделей. Статья подчеркивает, что интеграция ИИ в ГИС способствует повышению точности и эффективности анализа геоданных в различных областях, от промышленного мониторинга и сельского хозяйства до картографирования и городского планирования, и намечает перспективы дальнейшего развития этих технологий.

Annotation. The article focuses on the application of neural network models in geographic information systems (GIS) to automate the process of object detection on terrain using aerial imagery data. The drawbacks of manual data processing, such

as high cost, low productivity, and risk of errors, are discussed, as well as the advantages of implementing artificial intelligence (AI). The authors analyze various convolutional neural network (CNN) architectures, including R-CNN, YOLO, SSD, and specialized approaches such as DFL-CNN, for addressing object detection tasks on aerial and satellite imagery under challenging conditions. The use of modern frameworks (PyTorch, TensorFlow) and specialized libraries (Raster Vision, TorchGeo) for model development and training is discussed. The article emphasizes that AI integration into GIS enhances the accuracy and efficiency of geospatial data analysis in various fields, from industrial monitoring and agriculture to mapping and urban planning, and outlines prospects for the further development of these technologies.

Ключевые слова: нейронные сети, ГИС, распознавание объектов, аэрофотосъемка, искусственный интеллект, сверточные нейронные сети, автоматизация, геопространственные данные, машинное обучение, мониторинг

Keywords: neural networks, GIS, object detection, aerial imagery, artificial intelligence, Convolutional Neural Networks, automation, geospatial data, machine learning, monitoring

До недавнего времени обнаружение и разметка объектов при обработке материалов аэрофотосъемки осуществлялись вручную [1], что приводило к высокой стоимости полученных цифровых ортофотопланов, снижению производительности и значительному риску ошибок детектирования. Затраты на такое детектирование могут значительно превышать стоимость самой аэрофотосъемки, а низкая производительность и риски снижения качества при визуальном анализе, особенно при работе с большими территориями в сотни или тысячи квадратных километров, подчеркивают высокую трудоемкость процесса. В связи с этим возникла острая потребность в автоматизации этого сложного и затратного процесса, где внедрение информационных систем с

применением искусственного интеллекта способно существенно повысить качество промышленного мониторинга.

В последние годы искусственный интеллект стал одним из наиболее активно развивающихся областей технологий, находящих широкое применение в географических информационных системах [2]. Интеграция ИИ в ГИС открывает новые возможности для анализа и обработки географических данных, что способствует более точному и эффективному их изучению. История применения ИИ в ГИС началась еще в 1960-х годах с экспертных систем, но настоящий прорыв произошел с развитием методов машинного и глубокого обучения в середине 1990-х и особенно в последние годы, благодаря доступности больших объемов геоданных и облачных вычислений [2]. ИИ позволяет ГИС автоматически распознавать объекты на картах, прогнозировать и моделировать географические процессы, а также оптимизировать маршруты и процессы принятия решений.

Основой для автоматизации процесса построения контуров объектов и их детектирования на ортофотопланах послужила сверточная нейронная сеть [1]. Convolutional Neural Networks (CNN), являются специализированным видом нейронных сетей, предназначенных для обработки данных с характерной топологией, подобной сетке, и чрезвычайно хорошо зарекомендовали себя в практическом применении [3,4]. Они используются для распознавания объектов, классификации изображений и видеоанализа [5]. Главное преимущество СНС заключается в их способности автоматически выявлять иерархию признаков, от простых границ до сложных объектов, а также в частичной устойчивости к изменениям масштаба, смещениям, поворотам и другим искажениям [6]. СНС имеет меньше настраиваемых весов по сравнению с полносвязными сетями, что снижает объем работы за счет обобщения информации. Кроме того, они позволяют работать с множеством изображений, что делает их идеальными для задач с высоким разрешением, где количество параметров обычной нейронной сети быстро бы росло.

Типовая структура сверточной нейронной сети включает множество слоев. После входного изображения сигнал проходит через серию сверточных слоев, где чередуются операции свертки и субдискретизации. Это чередование позволяет формировать карты признаков, которые уменьшаются в размере на каждом последующем слое, но увеличивают количество каналов, что обеспечивает распознавание сложных иерархий признаков. В конце сверточные слои передают обработанные данные на несколько полносвязных слоев [3]. Обучение нейронных сетей, включая сверточные, происходит с использованием метода обратного распространения ошибки [7]. В ходе обучения корректируются веса связей между элементами нейронной сети для минимизации ошибки между предсказанным и истинным значением, что осуществляется методом градиентного спуска. Применение контролируемого обучения (с учителем) с размеченным набором данных критически важно для оценки точности алгоритма. Для недостаточных объемов данных применяется техника трансферного обучения, при которой предобученные на других задачах модели дообучаются для конкретной задачи, позволяя использовать уже полученные знания [5].

Задача детектирования объектов на изображении, где количество объектов заранее неизвестно, требует выбора между различными методами. Существуют два основных подхода: метод, основанный на регионах (двухэтапный), и одноэтапный метод [7]. Двухэтапные методы, такие как R-CNN, Fast R-CNN и Faster R-CNN, сначала выделяют регионы интереса, а затем классифицируют объекты в этих регионах [3]. Они обеспечивают высокую точность, но требуют существенных временных затрат. Например, Faster R-CNN заменяет селективный поиск на небольшую нейронную сеть (RPN) для поиска регионов, значительно увеличивая скорость работы. Региональная полная сверточная сеть (R-FCN) также использует RPN, но удаляет полносвязные слои после слоя субдискретизации регионов, что сокращает число параметров и ускоряет работу. В отличие от них, одноэтапные методы, такие как YOLO (You Only Look Once) и SSD (Single Shot MultiBox

Detector), выполняют локализацию и классификацию одновременно, предсказывая координаты ограничивающих рамок и их классы за один проход. Это обеспечивает более высокую скорость работы.

Хотя YOLO эффективно предсказывает ограничивающие рамки для всего изображения, его функциональные возможности ограничены предсказанием только одного класса для каждой ячейки, что затрудняет обнаружение нескольких объектов в одной ячейке [1]. Поэтому для задачи детектирования объектов лучше выбрать алгоритм SSD. SSD включает принципы YOLO, но позволяет слою детектирования получать набор рамок с разных уровней сжатия изображения, что дает возможность детектировать объекты малых размеров и более точно работать с множеством объектов. Несмотря на эти достижения, обнаружение объектов на аэрокосмических снимках имеет ряд специфических трудностей, таких как произвольная ориентация объектов, вариации масштаба, неравномерная плотность объектов, сложные фоновые условия и большие соотношения сторон [3]. Для решения проблемы произвольной ориентации и больших соотношений сторон используются ориентированные ограничивающие рамки (OBB) вместо горизонтальных (HBB), что обеспечивает более точную локализацию.

Для улучшения распознавания объектов, особенно транспортных средств, на аэрофотоснимках, где объекты могут быть монотонными и фон сложным, была разработана модель сверточной нейронной сети с двойной потерей фокуса (DFL-CNN) [8]. Эта модель включает пропускающее соединение от нижних слоев к верхним для изучения детальной информации, а также использует функцию потери фокуса вместо перекрестной энтропии. Функция потери фокуса помогает справиться с дисбалансом классов и различать легко- и трудно классифицируемые примеры, что особенно актуально для плотных парковок или объектов, похожих на фон. Помимо этого, для работы с аэрофотоснимками применяются методы аугментации данных, такие как повороты и изменение яркости, чтобы модель могла распознавать объекты в

различных условиях [5]. Для снимков сверхвысокого разрешения часто используется разбиение изображений на фрагменты с последующей сборкой результатов, что позволяет сохранить детализацию без чрезмерной нагрузки на вычислительные ресурсы.

Для практической реализации описанных подходов и преодоления упомянутых сложностей разработчики и исследователи активно используют как универсальные фреймворки глубокого обучения, так и специализированные библиотеки, адаптированные для работы с геопространственной информацией.

Среди универсальных фреймворков наиболее популярными являются PyTorch и TensorFlow. Они предоставляют гибкие возможности для построения и обучения сложных нейросетевых архитектур, включая сверточные нейронные сети, которые лежат в основе большинства современных систем распознавания изображений. Эти фреймворки позволяют исследователям реализовывать самые передовые алгоритмы, экспериментировать с различными конфигурациями моделей и оптимизировать их для конкретных задач. TensorFlow, например, известен своей масштабируемостью и возможностями для развертывания моделей в производственной среде, в то время как PyTorch часто предпочитают за его интуитивность и гибкость в процессе исследований. Многие ГИС-платформы, такие как ArcGIS Pro, также обеспечивают интеграцию с этими фреймворками, позволяя использовать обученные модели непосредственно в геоинформационных системах.

Несмотря на мощность и гибкость универсальных фреймворков, работа с геопространственными данными имеет свою специфику, связанную с большими объемами, наличием геопривязки, разнообразием форматов и необходимостью учета пространственных отношений. Для упрощения этих задач и ускорения процесса разработки были созданы специализированные библиотеки, построенные поверх PyTorch или TensorFlow, но

ориентированные именно на геопространственное применение. К таким библиотекам относятся, например, Raster Vision и TorchGeo.

Raster Vision представляет собой фреймворк с открытым исходным кодом, предназначенный для создания моделей компьютерного зрения на спутниковых и аэрофотоснимках. Он упрощает весь рабочий процесс, начиная от подготовки данных (например, нарезки больших изображений на более мелкие фрагменты – "чипы"), обучения моделей для задач классификации, детекции объектов и семантической сегментации, и заканчивая предсказанием и оценкой результатов. Raster Vision интегрируется с PyTorch и предоставляет инструменты для конфигурации экспериментов, что делает его доступным даже для пользователей, не являющихся экспертами в глубоком обучении.

TorchGeo – это библиотека на основе PyTorch, специально разработанная для облегчения работы с геопространственными данными в задачах машинного обучения. Она предоставляет удобные загрузчики для множества популярных наборов геопространственных данных, таких как Sentinel, Landsat и другие, а также функции для их предварительной обработки, аугментации и преобразования в форматы, пригодные для обучения нейронных сетей. Это значительно сокращает время, затрачиваемое на подготовку данных, и позволяет исследователям сосредоточиться непосредственно на разработке и обучении моделей.

Применение нейросетевых моделей уже активно используется в ведущих картографических сервисах и других отраслях. Например, 2ГИС использует сверточные нейронные сети для анализа земельных участков, разделения элементов на цифровых картах (здания, дороги, водные объекты) и автоматической идентификации сущностей [9]. Google Maps также применяет СНС и алгоритмы компьютерного зрения для повышения точности и детализации картографических материалов. В сельском хозяйстве нейросети способны анализировать миллионы фотографий, различая культуры от сорняков, определяя состояние растений, прогнозируя урожай и даже сортируя

собранный урожай [4]. В области мониторинга инфраструктуры компьютерное зрение позволяет автоматизировать выявление повреждений дорожного полотна и оценку состояния зданий. Экологический мониторинг использует анализ аэроснимков для отслеживания изменений лесного покрова и выявления незаконных вырубок. Городское планирование также выигрывает от анализа аэроснимков для оценки плотности застройки и планирования инфраструктуры.

Таким образом, применение нейросетевых моделей в ГИС для распознавания объектов на местности ознаменовало значительный прогресс, позволив перейти от трудоемких ручных методов к высокоэффективным автоматизированным системам. Это не только кардинально сокращает временные и финансовые затраты, но и повышает точность и эффективность анализа геоданных в широком спектре задач, от промышленного мониторинга и сельского хозяйства до картографирования и городского планирования.

Успешное внедрение требует комплексного подхода. Он включает выбор оптимальных архитектур нейронных сетей, таких как сверточные нейронные сети и SSD, адаптацию к специфике аэрокосмических снимков, что достигается, например, применением моделей DFL-CNN или использованием ориентированных ограничивающих рамок. Также необходимо применение специализированных фреймворков и библиотек, включая PyTorch, TensorFlow, Raster Vision и TorchGeo, которые упрощают разработку и обучение.

Перспективы дальнейшего развития связаны с совершенствованием моделей для обработки еще более сложных сценариев с большим количеством объектов и вариативностью их отображения. Важна также более глубокая интеграция мультимодальных данных, к примеру, сочетание оптических снимков с данными LiDAR, и разработка систем, способных к анализу в режиме реального времени непосредственно в процессе съемки. Это открывает путь к созданию еще более интеллектуальных и адаптивных ГИС, способных решать актуальные задачи с беспрецедентной скоростью и

качеством, минимизируя влияние человеческого фактора и повышая общую эффективность мониторинга и управления территориями.

Список литературы

1. Назаров Т.Р., Мамедова Н.А. Автоматизированное решение задачи детектирования промышленных объектов на ортофотоплане с помощью нейронной сети // Программные продукты и системы. 2023. Т. 36. № 1. С. 144–158. DOI: 10.15827/0236-235X.141.144-158.
2. Аманкулова Н. А., Молмакова М. С., Каримова Г. Т. Искусственный интеллект и геоинформационные системы // Бюллетень науки и практики. 2023. Т. 9. № 11. С. 278–287.
3. Скрипачев В.О., Гуйда М. В., Гуйда Н. В., Жуков А. О. Исследование сверточных нейронных сетей для обнаружения объектов на аэрокосмических снимках // International Journal of Open Information Technologies. 2022. Т. 10. № 7. С. 54–64.
4. Погоньшев В. А., Погоньшева Д. А., Ториков В. Е. Нейронные сети в цифровом сельском хозяйстве // Вестник ФГОУ ВПО Брянская ГСХА. 2021. №5 (87). С. 68–71.
5. Зарипова Д. Н., Шлеймович М. П. Применение свёрточных нейронных сетей (CNN) для детекции объектов на аэроснимках // Вестник науки. 2025. Т. 2. № 5 (86). С. 808–815.
6. Войцеховский С.В., Бугаёва Я.В., Касавцев М.Ю., Кириенко А.Б. Модель системы распознавания наземных объектов на основе нейронной сети // Известия ТулГУ. Технические науки. 2022. №7. С 115-123.
7. Тисецкий А.Т., Ковалев Д.И., Мансурова Т.П. Обзор методов сегментации и обнаружения объектов на изображении в реальном времени для предотвращения аварийных ситуаций РЖД // Современные инновации, системы и технологии. 2022. №3. С. 101-116.

8. Ян М.Ю., Ляо В., Ли С., Цао Ю., Розенхан Б. Детектирование транспортных средств на аэрофотоснимках // Фотограмметрия и дистанционное зондирование. 2019. Т. 85, № 4. С. 297–304.
9. Экимов Д. В., Такташкин Д. В. Использование искусственных нейронных сетей для решения задач позиционирования объектов на цифровых картах // Вестник Пензенского государственного университета. 2025. № 1. С. 140–144.

References

1. Nazarov T.R., Mamedova N.A. Automated solution of the problem of detecting industrial objects on a orthomosaic using a neural network. *Software & Systems*, 2023, vol. 36, no. 1, pp. 144–158. DOI: 10.15827/0236-235X.141.144-158.
2. Amankulova N. A., Molmakova M. S., Karimova G. T. Artificial intelligence and geoinformation systems // *Bulletin of Science and Practice*. 2023. Vol. 9. No. 11. pp. 278–287.
3. Skripachev V.O., Guida M. V., Guida N. V., Zhukov A. O. Investigation of convolutional neural networks for object detection in aerospace imagery // *International Journal of Open Information Technologies*. 2022. Vol. 10. No. 7. pp. 54–64.
4. Pogonyshev V. A., Pogonysheva D. A., Torikov V. E. Neural networks in digital agriculture // *Bulletin of the Bryansk State Agricultural Academy*. 2021. No. 5 (87). pp. 68–71.
5. Zaripova D. N., Shleymovich M. P. Application of convolutional neural networks (CNN) for object detection on aerial images // *Bulletin of Science*. 2025. Vol. 2. No. 5 (86). pp. 808–815.
6. Voytsekhovskiy S.V., Bugayeva Ya.V., Kasavtsev M.Yu., Kirienko A.B. Model of a ground object recognition system based on a neural network // *Proceedings of Tula State University. Technical Sciences*. 2022. No. 7. pp. 115–123.

7. Tisetsky A.T., Kovalev D.I., Mansurova T.P. Review of real-time image segmentation and object detection methods for preventing emergency situations at Russian Railways (RZhD) // Modern Innovations, Systems and Technologies. 2022. No. 3. pp. 101-116.
8. Yang M.Y., Liao W., Li X., Cao Y., Rosenhahn B. Vehicle Detection in Aerial Images // Photogrammetric Engineering & Remote Sensing. 2019. Vol. 85, № 4. P. 297–304.
9. Ekimov D. V., Taktashkin D. V. Use of artificial neural networks for solving object positioning tasks on digital maps // Bulletin of Penza State University. 2025. No. 1. pp. 140–144.