
ПРИБОРЫ И МЕТОДЫ ИССЛЕДОВАНИЙ

RESEARCH INSTRUMENTS AND METHODS

УДК 004.04, 004.6

ДЕТЕКТИРОВАНИЕ НОВЫХ АНТРОПОГЕННЫХ ОБЪЕКТОВ НА РАЗНОВРЕМЕННЫХ СПУТНИКОВЫХ ИЗОБРАЖЕНИЯХ БЕЛОРУССКОЙ КОСМИЧЕСКОЙ СИСТЕМЫ ДИСТАНЦИОННОГО ЗОНДИРОВАНИЯ ЗЕМЛИ

Л. В. СЕМЕНЕНКО¹⁾, Е. Н. КОЧИК¹⁾, А. М. СОРОКА²⁾

¹⁾Институт прикладных физических проблем им. А. Н. Севченко БГУ,
ул. Курчатова, 7, 220045, г. Минск, Беларусь

²⁾Независимый исследователь, г. Заславль, Беларусь

Аннотация. Рассматривается решение задачи детектирования новых антропогенных объектов при проведении экологического мониторинга территории Беларуси с использованием разновременных панхроматических спутниковых изображений Белорусской космической системы дистанционного зондирования Земли и нейронной сети

Образец цитирования:

Семененко ЛВ, Кочик ЕН, Сорока АМ. Детектирование новых антропогенных объектов на разновременных спутниковых изображениях Белорусской космической системы дистанционного зондирования Земли. *Журнал Белорусского государственного университета. Физика*. 2025;3:62–69. EDN: UENNFZ

For citation:

Semianenka LV, Kochyk EN, Saroka AM. New anthropogenic objects detection in multi-temporal satellite images of the Belarusian space system of Earth remote sensing. *Journal of the Belarusian State University. Physics*. 2025;3:62–69. Russian. EDN: UENNFZ

Авторы:

Леонид Владимирович Семененко – кандидат технических наук; заведующий лабораторией информационных технологий.

Евгений Николаевич Кочик – старший научный сотрудник лаборатории информационных технологий.

Александр Михайлович Сорока – независимый исследователь.

Authors:

Leaid V. Semianenka, PhD (engineering); head of the laboratory of information technology.

lv_semenenko@mail.ru

<https://orcid.org/0009-0007-1413-0243>

Eugene N. Kochyk, senior researcher at the laboratory of information technology.

eugene.kochik@gmail.com

<https://orcid.org/0009-0009-7007-3436>

Aliaksandr M. Saroka, independent researcher.

soroka.a.m@gmail.com

<https://orcid.org/0009-0003-4012-477X>

глубокого обучения, обеспечивающей максимально достоверное обнаружение изменений наземных объектов при минимизации ложных срабатываний. Для реализации данной задачи выполнен анализ моделей нейронных сетей глубокого обучения для детектирования новых антропогенных объектов на основе семантической сегментации разновременных спутниковых изображений, по результатам которого выбрана модель нейронной сети глубокого обучения с проверкой гипотезы о необходимости обучения на собственной сформированной выборке антропогенных объектов. Проведено обучение выбранной модели нейронной сети глубокого обучения для реализации задачи детектирования новых антропогенных объектов на основе разновременных панхроматических спутниковых изображений с оптимизацией настроек и подбором гиперпараметров. Исходя из полученных результатов, сделан вывод о реальной возможности автоматизации контроля появления новых антропогенных объектов при проведении экологического мониторинга.

Ключевые слова: детектирование; экологический мониторинг; разновременные спутниковые изображения; Белорусская космическая система дистанционного зондирования Земли; нейронная сеть; глубокое обучение; семантическая сегментация.

NEW ANTHROPOGENIC OBJECTS DETECTION IN MULTI-TEMPORAL SATELLITE IMAGES OF THE BELARUSIAN SPACE SYSTEM OF EARTH REMOTE SENSING

L. V. SEMIANENKA^a, E. N. KOCHYK^a, A. M. SAROKA^b

*^aA. N. Sevchenko Institute of Applied Physics Problems, Belarusian State University,
7 Kurchatava Street, Minsk 220045, Belarus*

^bIndependent researcher, Zaslavl, Belarus

Corresponding author: E. N. Kochyk (eugene.kochik@gmail.com)

Abstract. The article considers the solution to the problem of detecting new anthropogenic objects during environmental monitoring in the territory of Belarus using multi-temporal panchromatic satellite images of the Belarusian space system of Earth remote sensing and a deep learning neural network that ensures the most reliable detection of changes in ground objects while minimising false positives. To solve this problem, an analysis of deep learning neural network models for detecting new anthropogenic objects based on semantic segmentation of multi-temporal satellite images was carried out. Based on this results, a deep learning neural network model was selected, the hypothesis about the need for training on our own formed dataset of anthropogenic objects was tested, training and validation datasets were formed. The training of the selected deep learning neural network model, including the optimisation of settings and selection of hyperparameters, was carried out to implement the task of detecting new anthropogenic objects based on multi-temporal panchromatic satellite images. The obtained results of this research showcased the practical feasibility of automating the detection of new anthropogenic objects during environmental monitoring.

Keywords: detection; environmental monitoring; multi-temporal satellite images; Belarusian space system of Earth remote sensing; neural network; deep learning; semantic segmentation.

Введение

Применение нейронных сетей для обработки данных дистанционного зондирования Земли в основном направлено на обнаружение определенных объектов.

В число актуальных задач, которые возникают при обработке данных, полученных с помощью систем дистанционного зондирования Земли, входит обнаружение новых объектов на основе анализа разновременной пары изображений, покрывающих одну территорию. С использованием разработанных методик может выполняться контроль появления новых антропогенных объектов в природной среде, наличия новых объектов строительства и т. д.

Как было установлено в ходе ранее проведенных исследований, автоматизация мониторинга изменений наземных объектов на разновременных снимках Белорусской космической системы дистанционного зондирования Земли (далее – БКСДЗ) на территории Беларуси имеет ряд существенных проблем [1]. Дополнительно можно отметить, что решение данной задачи требует распознавания релевантных изменений, а также снижения влияния срабатываний, вызванных схожими (ложными) объектами. При практическом применении разработанных методик важно учитывать, что нейронные сети не могут обеспечить 100 % обнаружение новых объектов, в связи с чем необходима заверка полученных результатов оператором на основе визуального анализа. По этой причине одной из актуальных задач является обеспечение качественных результатов распознавания, которые позволят минимизировать работу оператора по их заверке.

Для решения указанной задачи выполнен анализ моделей нейронных сетей глубокого обучения для детектирования новых антропогенных объектов на основе разновременных спутниковых изображений, выбрана оптимальная модель нейронной сети глубокого обучения и проведено ее обучение на сформированной выборке антропогенных объектов.

Анализ моделей нейронных сетей глубокого обучения для детектирования новых антропогенных объектов на основе разновременных спутниковых изображений

Предметную задачу детектирования новых антропогенных объектов на основе разновременных спутниковых изображений можно определить следующим образом: выявление изменений определенного типа между парами спутниковых снимков.

В большинстве случаев применение нейронных сетей для обработки данных дистанционного зондирования Земли проводится с использованием свободно предоставляемых мультиспектральных спутниковых изображений с пространственным разрешением от 10 м на 1 пк и выше (т. е. границы объектов можно определять с точностью до 30–50 м). В то же время для качественного контроля и анализа обычно требуется более высокая точность.

Для повышения пространственного разрешения используются панхроматические спутниковые снимки БКСДЗ, а именно снимки Белорусского космического аппарата и родственного ему космического аппарата «Канопус-В» с разрешением 2,1 м на 1 пк (т. е. границы объектов можно определять с точностью до 6–8 м). Подробная информация о характеристиках целевой аппаратуры приведена в статье [2, с. 14–15].

Формальную постановку задачи можно определить следующим образом: семантическая сегментация изображений с разделением на два класса – «нет изменений», «есть изменения».

Задача обнаружения изменений на парах спутниковых снимков в настоящее время успешно решается для некоторых схожих задач с использованием нейронных сетей глубокого обучения. В статье [3] проведено сравнение следующих существующих моделей: *FC-EF* [4], *FC-Siam-Di* [4], *FC-Siam-Conc* [4], *DTCDCN* [5], *STANet* [6], *IFNet* [7], *SNUNet* [8], *BIT* [9], *ChangeFormer* [3].

Как отмечено в настоящем исследовании, решение вышеуказанной задачи с помощью нейронной сети *ChangeFormer* показывает наилучший результат при тестировании модели на подобного рода задачах в случае использования двух стандартных наборов данных – LEVIR-CD [6] и DSIFN-CD [7].

Для детектирования новых антропогенных объектов на основе разновременных спутниковых изображений в рамках настоящего исследования интерес представляет не только максимально достоверное выявление изменений без пропусков, но и минимизация количества ложных срабатываний, так как каждое ложное срабатывание будет приводить к увеличению времени работы оператора, осуществляющего визуальную заверку результатов обработки спутниковых данных.

Чтобы в процессе обучения одновременно максимизировать точность детектирования объектов и минимизировать количество ложных срабатываний, необходимо использовать метрику качества, которая будет учитывать оба этих параметра. К числу наиболее известных и широко применяемых метрик подобного рода принадлежит метрика *F1* [10], которая является гармоническим средним точности и полноты и учитывает как точность алгоритма, так и количество ложных срабатываний.

Кроме того, метрика *F1* используется для оценки качества работы алгоритмов в статье [6], что в дальнейшем позволит оценить качество работы нейронной сети, обученной на сформированном нами наборе данных. Для стандартных наборов данных LEVIR-CD и DSIFN-CD значение метрики *F1* составляет 0,904 и 0,866 7 соответственно. Так как эти наборы данных составлены из мультиспектральных спутниковых снимков с более высоким пространственным разрешением, чем панхроматические

снимки БКСДЗ, можно ожидать, что для рассматриваемого случая приемлемым значением метрики $F1$ было бы значение $\sim 0,8$.

Тестирование и предварительное обучение выбранной нейронной сети

Для первичной валидации полученных результатов на имеющихся снимках БКСДЗ визуально были выбраны несколько явных объектов, которые появились на позднем снимке. Ни один из этих объектов не был детектирован предобученной моделью, поэтому потребовалось дообучение модели с настройками, которые использовались для стандартного набора данных LEVIR-CD.

Обучение выбранной нейронной сети проводилось с расчетом, что в случае, если не возникнет проблем, можно будет выполнить аугментацию таким образом, чтобы сеть начала детектировать изменения и на сформированном наборе данных. Для решения именно задачи определения изменений было проведено дообучение модели (т. е. без обучения самого трансформера). Однако такой подход не привел к улучшению результатов.

На основе анализа отрицательных результатов была выдвинута следующая гипотеза: предварительно обученная на стандартном наборе данных LEVIR-CD нейронная сеть не определяет изменения на снимках БКСДЗ, так как они существенно отличаются по разрешению от снимков, используемых в работе [6]. Кроме того, в наборе данных LEVIR-CD используются мультиспектральные снимки со спектральными каналами RGB. Для тестирования этой гипотезы была проведена следующая аугментация данных.

1. Снимки преобразовываются в оттенки серого (*grayscale*).
2. Применяется масштабирование снимков (пространственное разрешение изображений уменьшается в 4–5 раз для получения разрешения 2 Мпк).

Результат обучения нейронной сети подтвердил выдвинутую гипотезу: нейронная сеть начала детектировать изменения на снимках БКСДЗ, которые не участвовали в обучении. Однако обучение на данных существующих датасетов не дает хороших результатов (значение метрики $F1$ не превышало 0,16).

Исходя из вышесказанного, приходим к выводу, что выбранную нейронную сеть можно использовать для детектирования новых антропогенных объектов на основе разновременных спутниковых изображений, но при этом необходимо проводить разметку собственных данных и дообучение сети на сформированной выборке.

Описание процесса обучения выбранной нейронной сети

На основе проведенного анализа для обнаружения новых антропогенных объектов на основе разновременных спутниковых изображений выбрана архитектура нейронной сети *ChangeFormer* (github.com/wgcbn/changeformer).

Архитектура нейронной сети *ChangeFormer* (рис. 1) построена на основе трансформера для обнаружения изменений посредством анализа разновременной пары изображений, покрывающих одну территорию. В отличие от фреймворков, которые основаны на полностью сверточных сетях, предлагаемый метод объединяет иерархически структурированный преобразователь-кодировщик с декодером многослойного восприятия (MLP) для эффективного рендеринга многомасштабных деталей дальнего действия, необходимых для точного обнаружения изменений.

Для обучения выбранной нейронной сети использовался метод оптимизации *AdamW* [11] со следующими настройками, которые обеспечили достижение наилучшего значения метрики качества обучения: `weight_decay=0.4037599735608572; batch_size=32; lr=0.00001; policy=cosine; optimizer=adamw, loss=ce`.

Каждый обучающий пример состоит из пары сегментов размером 256×256 пк, который на шаге обучения готовится посредством итерации по объектам эталонной разметки следующим образом.

1. Первая вершина объекта эталонной разметки задает центр рассматриваемого региона размером 1024×1024 пк.
2. Для рассматриваемого региона визуализируется маска объектов интереса.
3. Из снимков и маски объектов интереса случайно вырезаются области, размер которых соответствует входному разрешению нейронной сети (256×256 пк).

На этапе тестирования рассматриваются регионы размером 256×256 пк, чтобы избежать случайного изменения валидационных примеров.




Рис. 1. Архитектура нейронной сети *ChangeFormer*.

Источник: [3]

Fig. 1. *ChangeFormer* network architecture.

Source: [3]

Для уменьшения склонности нейронной сети к переобучению применяются следующие методы аугментации.

1. Методы, применяемые для более старого снимка:

- случайное изменение яркости и контраста – `A.RandomBrightnessContrast()`;
- случайное изменение гаммы изображения – `A.RandomGamma()`;
- случайный сдвиг на 2 пк по горизонтали и 6 пк по вертикали – `A.augmentations.geometric.transforms.Affine(translate_px=dict(x=(-2, 2), y=(-6, 6)))`.

2. Методы, применяемые для обоих снимков и эталонной разметки совместно:

- зеркальное отражение по вертикали и горизонтали – `A.Flip()`;
- случайное масштабирование снимка в интервале $[0,75, 1,25]$ – `A.RandomScale(scale_limit=(0.2, 1.03), p=1, interpolation=cv2.INTER_AREA)`;
- случайное вырезание региона размером 256×256 пк – `A.RandomCrop(256, 256, p=1)`;
- случайное вращение с шагом 90° – `A.RandomRotate90(p=0.9)`;
- случайное транспонирование – `A.Transpose(p=0.25)`;
- случайное инвертирование изображения – `A.InvertImg(p=0.1)`;
- случайное масштабирование значения каждого пиксела в интервале $[0,95, 1,05]$ – `A.MultiplicativeNoise(elementwise=True)`;
- случайное изменение яркости и контраста – `A.RandomBrightnessContrast()`;
- случайное изменение гаммы изображения – `A.RandomGamma()`.

С использованием выбранной нейронной сети проведена автоматическая разметка всех имеющихся пар спутниковых снимков, по результатам которой выполнены следующие действия.

1. В обучающей выборке исправлены пропуски истинных объектов и добавлены наиболее часто встречающиеся ложные объекты.

2. В валидационной выборке добавлены истинные объекты (по несколько штук на пару снимков) и добавлено большее количество ложных объектов, поскольку на некоторых парах снимков было значительное количество ложных срабатываний.

Для проведения обучающей разметки использовано восемь пар снимков, которые покрывали разные регионы Беларуси или территории различной степени урбанизированности и техногенной освоенности либо были получены в разные сезоны года (период с марта по ноябрь), что увеличивало вариативность распознаваемых объектов. Всего в обучающей выборке размечено 4090 истинных объектов и 7300 ложных объектов на территории площадью 32,2 тыс. км².

Валидационная разметка была проведена на двух парах снимков по тем же принципам, что и обучающая разметка. Всего в валидационной выборке размечено 460 истинных объектов и 780 ложных объектов на территории площадью 3,8 тыс. км².

Для оценки точности полученного решения применялось среднее пересечение по объединению (метрика *mIoU*) с использованием процедуры скользящего контроля и разделением исходного набора данных на обучающий и валидационный наборы данных:

$$mIoU = \frac{1}{N} \sum_{i=1}^N \frac{P_i \cap L_i}{P_i \cup L_i},$$

где P_i – множество пикселей, которые классифицированы нейронной сетью глубокого обучения как относящиеся к i -му классу; L_i – множество пикселей, относящихся к i -му классу из эталонной разметки; $N = 2$ – число классов.

В связи с тем что общее число пикселей фона значительно превышает число пикселей истинных объектов, была использована функция потерь (L) [12], в которой весовые коэффициенты для каждого класса определены экспериментальным путем:

$$L = \sum_{i=1}^W \sum_{j=1}^H \sum_{n=1}^N A_n T_{ijn} \ln \left(\frac{O_{ij}}{\sum_{l=1}^W \sum_{k=1}^H O_{lk}} \right),$$

где W – ширина изображения; H – высота изображения; A_n – экспериментально подобранный для каждого класса весовой коэффициент; T_{ijn} – значение пиксела в оригинальной разметке; O_{ij} – элемент выхода нейронной сети глубокого обучения.

Далее было проведено обучение выбранной нейронной сети для детектирования новых антропогенных объектов на основе разновременных спутниковых изображений.

Путем подбора гиперпараметров за 10 эпох обучения удалось добиться значения метрики $F1$, равного 0,62. Затем было проведено дальнейшее обучение модели в течение большего количества эпох с заменой метрики $F1$ на метрику $mIoU$. За 200 эпох обучения значение метрики $mIoU$ достигло 75,76 %.

Примеры работы обученной нейронной сети приведены на рис. 2 и 3.



Рис. 2. Новая ферма в Слонимском районе

Fig. 2. New farm in Slonim District



Рис. 3. Новая ферма в Вороновском районе

Fig. 3. New farm in Voronovsky District

Заклучение

При проведении настоящего исследования получены следующие результаты.

1. Разработана методика анализа и выбора моделей нейронных сетей глубокого обучения для детектирования новых антропогенных объектов на основе разновременных спутниковых изображений.
2. Выполнен анализ моделей нейронных сетей глубокого обучения для детектирования новых антропогенных объектов на основе разновременных снимков БКСДЗ, и осуществлен выбор модели нейронной сети глубокого обучения для реализации данной задачи.
3. Проведено предварительное обучение выбранной модели нейронной сети глубокого обучения, которое показало, что эту модель нейронной сети можно использовать для детектирования новых антропогенных объектов на основе разновременных снимков БКСДЗ при условии создания собственного обучающего набора данных и проведения дообучения сети.

4. Созданы обучающая и валидационная выборки на восьми парах разновременных снимков (в общей сложности 4550 истинных объектов и 8080 ложных объектов), проведено обучение нейронной сети с оптимизацией настроек и подбором гиперпараметров.

5. Получены положительные результаты обнаружения новых антропогенных объектов на основе разновременных спутниковых изображений с метрикой $mIoU$, равной 75,76 %.

Таким образом, результаты исследования наглядно демонстрируют реальную возможность автоматизации контроля появления новых антропогенных объектов при проведении экологического мониторинга. Разработанная модель используется в комплексе программных средств обработки данных дистанционного зондирования Земли в рамках Информационно-аналитической системы контроля и анализа деятельности в водоохранных зонах (ИАС «Водоохранные зоны») и уже на этом этапе эффективно справляется с поставленной задачей. Возможно дальнейшее повышение точности, однако для получения значимых с предметной точки зрения результатов потребуются наличие большого количества ресурсов, которые обеспечат кратное расширение обучающего набора данных.

Библиографические ссылки

1. Белозерский ЛА, Мурашко НИ, Орешкина ЛВ. Проблемы использования разновременных спутниковых снимков в решении задач автоматического обнаружения изменений на местности. В: Абрамеев СВ, Казаченок ВВ, Красногир ЕГ, Буза МК, Воронников ЮИ, Журавков МА и др., редакторы. *Международный конгресс по информатике: информационные системы и технологии. Материалы Международного научного конгресса; 24–27 октября 2016 г.; Минск, Беларусь*. Минск: БГУ; 2016. с. 4–8.
2. Макриденко ЛА, Волков СН, Горбунов АВ, Салихов РС, Ходненко ВП. КА «Канопус-В» № 1 – первый российский малый космический аппарат высокоточного дистанционного зондирования Земли нового поколения. *Вопросы электромеханики. Труды ВНИИЭМ*. 2017;156:10–20. EDN: YWELEH.
3. Bandara WGC, Patel VM. A transformer-based Siamese network for change detection. In: Institute of Electrical and Electronics Engineers. *IGARSS-2022. Proceedings of the 2022 IEEE International geoscience and remote sensing symposium; 2022 July 17–22; Kuala Lumpur, Malaysia*. [S. l.]: Institute of Electrical and Electronics Engineers; 2022. p. 207–210. DOI: 10.1109/IGARSS46834.2022.9883686.
4. Daudt RC, Le Saux B, Boulch A. Fully convolutional Siamese networks for change detection. In: Institute of Electrical and Electronics Engineers. *2018 25th IEEE International conference on image processing (ICIP); 2018 October 7–10; Athens, Greece*. [S. l.]: Institute of Electrical and Electronics Engineers; 2018. p. 4063–4067. DOI: 10.1109/ICIP.2018.8451652.
5. Liu Y, Pang C, Zhan Z, Zhang X, Xue Yang X. Building change detection for remote sensing images using a dual-task constrained deep Siamese convolutional network model. *IEEE Geoscience and Remote Sensing Letters*. 2021;18(5):811–815. DOI: 10.1109/LGRS.2020.2988032.
6. Chen H, Shi Z. A spatial-temporal attention-based method and a new dataset for remote sensing image change detection. *Remote Sensing*. 2020;12(10):1662. DOI: 10.3390/rs12101662.
7. Zhang C, Yue P, Tapete D, Jiang L, Shangguan B, Huang L, et al. A deeply supervised image fusion network for change detection in high resolution bi-temporal remote sensing images. *ISPRS Journal of Photogrammetry and Remote Sensing*. 2020;166:183–200. DOI: 10.1016/j.isprsjprs.2020.06.003.
8. Fang S, Li K, Shao J, Li Z. SNUNet-CD: a densely connected Siamese network for change detection of VHR images. *IEEE Geoscience and Remote Sensing Letters*. 2021;19:8007805. DOI: 10.1109/LGRS.2021.3056416.
9. Chen H, Qi Z, Shi Z. Remote sensing image change detection with transformers. *IEEE Transactions on Geoscience and Remote Sensing*. 2022;60:5607514. DOI: 10.1109/TGRS.2021.3095166.
10. van Rijsbergen CJ. *Information retrieval*. 2nd edition. London: Butterworths; 1979. 208 p.
11. Loshchilov I, Hutter F. Decoupled weight decay regularization. In: *Proceedings of the 7th International conference on learning representations (ICLR-2019); 2019 May 6–9; New Orleans, USA. Volume 6*. Red Hook: Curran Associates; 2019. p. 4061–4078.
12. Ronneberger O, Fischer P, Brox T. U-Net: convolutional networks for biomedical image segmentation. In: Navab N, Hornegger J, Wells WM, Frangi AF, editors. *Medical image computing and computer-assisted intervention – MICCAI-2015. Proceedings of the 18th International conference; 2015 October 5–9; Munich, Germany. Part 3*. Cham: Springer; 2015. p. 234–241 (Lecture notes in computer science; volume 9351). DOI: 10.1007/978-3-319-24574-4_28.

Получена 20.02.2025 / исправлена 19.03.2025 / принята 19.03.2025.
Received 20.02.2025 / revised 19.03.2025 / accepted 19.03.2025.