

DOI 10.66032/2221-2574-2026-1-1-47-54

УДК 004.93

## ИСПОЛЬЗОВАНИЕ ТОПОЛОГИЧЕСКОГО АНАЛИЗА ДЛЯ КЛАССИФИКАЦИИ ТРАНСПОРТНЫХ СРЕДСТВ НА СПУТНИКОВЫХ СНИМКАХ

### **Абакумов Артём Владимирович**

аспирант, Муромский институт (филиал) ФГБОУ ВО «Владимирский государственный университет имени Александра Григорьевича и Николая Григорьевича Столетовых».

### **Еремеев Сергей Владимирович**

кандидат технических наук, доцент кафедры информационных систем Муромского института (филиала) ФГБОУ ВО «Владимирский государственный университет имени Александра Григорьевича и Николая Григорьевича Столетовых».

Адрес: 602264, Российская Федерация, Владимирская обл., г. Муром, ул. Орловская, д. 23.

E-mail для связи: [artem210966@yandex.ru](mailto:artem210966@yandex.ru)

**Аннотация:** В отличие от текстовой информации, выделить семантическую информацию на изображении сложнее в связи с сильным влиянием цвета пикселей друг на друга. Это усложняет алгоритмизацию анализа изображений в задачах, где важно понимание содержимого изображения. В частности, такой задачей является классификация объектов на изображении. Лучше всего эту задачу решают нейросетевые подходы, т.к. они способны установить связь между пикселями, но это требует высоких вычислительных ресурсов и больших обучающих данных для качественной работы. В данном исследовании предлагается альтернативный подход, который решает задачу классификации транспортных средств на спутниковых снимках с помощью топологического анализа данных. Разработанная технология учитывает структуру объекта и показывает высокую точность для классов самолётов и машин. Общая точность классификации у предлагаемого решения составляет 93%, что сопоставимо с нейронной сетью ResNet-18, которая показывает точность 96%. Но технология требует доработки для классификации объектов, у которых отсутствует вариация яркости, что частично решается в данной работе, и будет дополнительно изучаться в дальнейших исследованиях.

**Ключевые слова:** топологический анализ данных, классификация, обработка изображений, спутниковые снимки, обнаружение объектов.

### **Введение**

В последнее время становятся все более доступными пространственные данные сверхвысокого разрешения. Это открывает новые возможности для анализа детальной информации на снимках высокой точности.

Рассмотрим современные подходы для обнаружения объектов на изображениях, в большей степени ориентированные на идентификацию и классификацию транспортных средств.

Выделим сначала группу методов, которые используют для решения этих задач нейронные сети. В [1] предложена архитектура сети, в основе которой лежит сверточная нейронная сеть Faster R-CNN в интеграции с модулем Feature Pyramid Network. Авторы показывают улучшение точности при классификации транспортных средств по сравнению со сверточной нейронной

сетью YOLO v4. Модели серии YOLO, в свою очередь, зарекомендовали себя как очень эффективный инструмент для классификации большого числа объектов на изображениях. Очень много исследователей по всему миру вносят доработки в YOLO для повышения точности в задачах поиска объектов [2, 3].

В исследовании [4] также рассматриваются снимки высокого разрешения, но используется адаптация архитектуры VGG16. Авторы снижают количество весов модели, но при этом сохраняют точность классификации. Задача снижения сложности нейронной сети при сохранении точности наблюдается также в [5], где говорится про острую необходимость в легковесных технологиях, которые могут работать в режиме реального времени.

В текущее время наблюдается тенденция для решения задачи поиска мелких объектов на

спутниковых снимках [6,7], а также использование результатов поиска для решения прикладных задач. Так, например, в [8] рассматривается классификация и анализ объектов в транспортном потоке, а в [9] выделение транспортных средств применяется для решения задач ситуационного управления в городе на основе модели Mask R-CNN и библиотеки OpenCV.

Другим направлением исследований при классификации объектов на спутниковых снимках являются традиционные подходы. В [10] используется контурный анализ сосредоточенных и площадных объектов, в основе которого лежит применение свёртки изображения по четырём направлениям, а также процедуры трассировки. Алгоритм позволяет повысить точность при выделении контуров объектов и не требует больших вычислительных ресурсов. В [11] для извлечения информации об объектах используется фильтр Калмана, а также алгоритм вычитания фона. В [12] рассматривается задача улучшения алгоритма SIFT для извлечения и сопоставления признаков на зашумленных спутниковых снимках. Также используются нечёткие признаки, основанные на геометрических характеристиках объектов [13]. В [14], в дополнении к геометрическим признакам, также используются текстурные.

Кроме того, используется сочетание нейросетевых технологий и предварительное вычисление признаков объектов на изображении. Например, в [15] в качестве признаков используются вейвлет коэффициенты, которые подаются на вход для нейросетевой модели.

Таким образом, среди множества существующих подходов классификации объектов можно выделить следующие группы: основанные на нейросетях и традиционные. Первые из них обладают более высокой точностью, но требуют больших вычислительных ресурсов. Вторая группа подходов нацелена на быстрые вычисления, но с потерей точности классификации. Поэтому целью данной работы является разработка технологии классификации объектов на изобра-

жениях, которая обеспечивает точность, сопоставимую с нейросетевыми подходами. При этом технология приближена к классу классических алгоритмов по принципу работы, но предусматривает учёт контекста на изображении.

### Семантическое представление изображения

Пиксели изображения, помимо яркостной характеристики, обладают семантической связью, которая позволяет человеческому глазу увидеть образ. При этом не все пиксели одинаково важны. Если убрать несколько строчек и столбцов в изображении размером 64 на 64, то человек не заметит разницы. Это же верно, если изменить яркость в пределах нескольких единиц. При этом сложно определить грань изменения изображения, когда семантическое содержимое можно считать изменившимся.

В компьютерном зрении семантика чаще всего представляется в виде набора признаков. Самый простой из них — гистограмма яркости. Лучше всего семантику «понимают» нейронные сети, оперируя тысячами параметров. При этом принцип работы нейронных сетей («чёрный ящик») не позволяет выявить чёткую теорию, как происходит это понимание, что делает работу нейронных сетей сложно прогнозируемой, особенно в условиях ограниченного объёма данных.

Изображение возможно рассматривать как набор ключевых регионов, каждый из которых определяется заметной яркостной границей. Многие алгоритмы выделения границ используют именно этот признак в своей основе. Этот принцип также прослеживается при топологическом анализе данных, где объекты описываются связанными областями и дырами.

Топологический анализ данных рассматривает изображение как набор сегментов, упорядоченных в виде дерева. Каждый сегмент отображается рядом стоящим набором пикселей. При правильном формировании этих сегментов каждый из них будет отображать объект или часть объекта на изображении, т.е. приблизится к семантическому содержимому на изображении. Но это справедливо только если объект обладает

минимальной топологической уникальностью. Например, белый круг диаметром 500 пикселей и квадрат 2 на 2 пикселя с точки зрения топологии являются одинаковыми. Поэтому топологический анализ данных применим не для всех типов объектов.

### Представление изображения в виде топологических сегментов

Если принять, что топологию изображения возможно представить в виде сегментов, то при сравнении этих сегментов получится вычислить схожесть изображений. Для этого необходимо использовать специальную характеристику — баркод. Он представляет из себя набор компонент связности (сегментов). Формирование баркода (т.е. сегментов) основано на яркости. Возможно несколько вариантов рассмотрения яркостной характеристики. В данной работе используется яркость между соседями.

Дано изображение  $I$  в виде матрицы пикселей. Необходимо получить баркод  $B = \{C_1, C_2, C_3, \dots, C_N\}$ . Каждая компонента  $C_i$  ( $i = 1, 2, \dots, N$ ) состоит из  $M_i$  пикселей, отображаемых на изображении.

Для получения баркода матрица  $I$  преобразуется в множество пар PAIRS =  $\{(p_i, p_j)\}$ , где  $p_i$  и  $p_j$  — соседние пиксели в изображении  $I$  в соответствующей области Мура. Каждой паре пикселей соответствует расстояние, вычисленное по норме:

$$d_{i,j} d_{i,j} = \|p_i - p_j\|_2, \quad (1)$$

где  $i, j$  — номера соседних пикселей.

Далее PAIRS сортируются по возрастанию значения  $d$ . После сортировки объекты из PAIRS поочерёдно извлекаются и передаются в алгоритм формирования сегментов, где возможны четыре сценария:

1. Если в точке  $p_i$  уже существует компонента, то к ней присоединяется точка  $p_j$ ;
2. Если в точке  $p_j$  уже существует компонента, то к ней присоединяется точка  $p_i$ ;

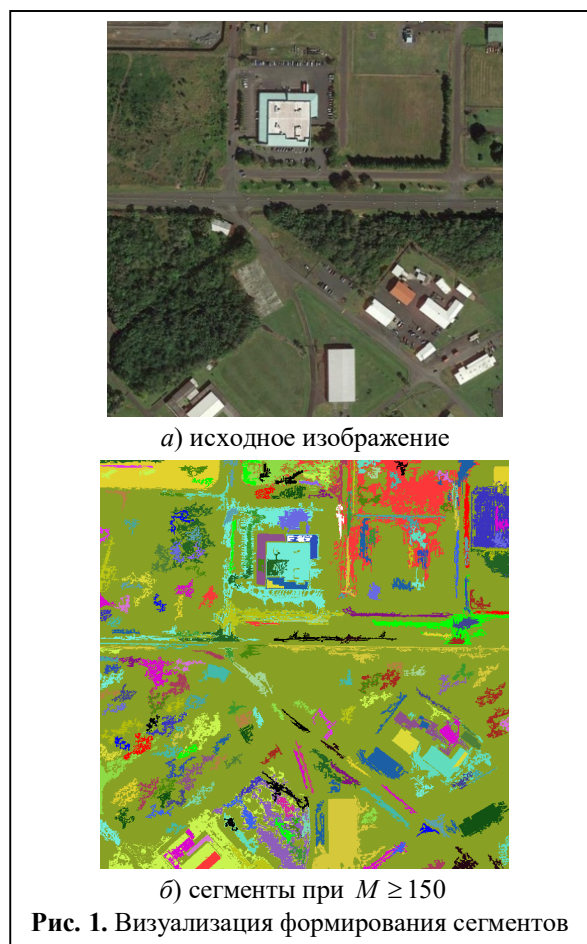
3. Если в точках  $p_i$  и  $p_j$  компоненты отсутствуют, то создаётся новая компонента, включающая обе точки;

4. Если точки  $p_i$  и  $p_j$  принадлежат разным компонентам, то компоненты объединяются. Компонента с большим числом точек становится родительской и включает все точки поглощённой компоненты. Поглощённая компонента помечается как сформированный сегмент и добавляется в баркод  $B$ .

Таким образом, ближайшие по яркости пиксели сформируют сегменты, схожие по яркости. Пример сегментов показан на рис. 1.

### Сравнение изображений по их топологии

Если на изображении дочерний элемент (группа пикселей) смещается, то с топологической точки зрения объект не меняется. Например, на спутниковом снимке два одинаковых дома, но с разным расположением дымоходов, будут считаться одинаковыми. В этом плане топология



приближена к человеческому восприятию схожести.

Для количественного выражения схожести необходимо определить функцию дистанции.

Пусть сегмент  $C$  задаётся топологическим свойством:

$$L = (l^s, l^e), l^s, l^e \in \mathbb{R},$$

где  $l^s, l^e$  — разницы яркостей (вычисленная по формуле (1)), при которой сегмент появился и исчез (при объединении с другой компонентой) соответственно.

При этом продолжительность существования сегмента определяется как  $TL(L) = l^e - l^s$ .

Таким образом, можно построить описание баркода  $BL$  в виде множества периодов существования сегментов:

$$BL = \{L_1, L_2, \dots, L_n\}.$$

Схожесть двух периодов существования  $L_1$  и  $L_2$  определяется как отношение длины их пересечения к максимальной длине:

$$C_{common}(L_1, L_2) = \frac{\max(0, \min(l_1^e, l_2^e) - \max(l_1^s, l_2^s))}{\max(TL(L_1), TL(L_2))},$$

где  $L_k = (l_k^s, l_k^e), k = 1, 2$ .

Без ограничения общности, для определения схожести двух баркодов  $BL_1$  и  $BL_2$  вводятся величины:

$$C_{it}(L_1, L_2) = C_{common}(L_1, L_2) * (TL(L_1) + TL(L_2)),$$

$$C_{total}(BL_1, BL_2) = \sum_{i=1}^{\max(TL(BL_1), TL(BL_2))} C_{it}(BL_1^i, BL_2^i),$$

$$C_{sum}(L_1, L_2) = \sum_{i=1}^{\max(TL(BL_1), TL(BL_2))} (TL(BL_1^i) + TL(BL_2^i)),$$

и окончательная метрика расстояния между двумя баркодами задаётся как:

$$C_{distance} = \begin{cases} \frac{C_{total}, C_{sum} > 0}{C_{sum}} \\ 0, C_{sum} = 0 \end{cases}. \quad (2)$$

### Классификация спутниковых снимков

Функция дистанции позволяют сгруппировать базовый набор элементов на основе эталонов, т.е. выполнить задачу классификации.

Технология классификации разделена на два этапа: обучение и предсказание.

Алгоритмическая реализация обучения состоит в том, чтобы сформировать  $K$  корзины, где  $K$  — количество классов. В каждую корзину будет помещён баркод эталона с соответствующим номером класса. Например, если задано 3 класса, то будет три корзины. В каждой — эталоны одного из классов.

Во время предсказания из входного объекта формируется баркод. Затем через функцию дистанции происходит сравнение со всеми эталонами по формуле (2). Выходным считается класс, у которого в корзине оказался ближайший элемент. Т.е. сложность алгоритма предсказания является  $O(N)$ , где  $N$  — количество эталонов.

### Тестирование технологии классификации

В данной работе решалась задача мульти-классовой классификации средств передвижения на спутниковых картах по заранее заданным зонам интереса. Для тестирования точности построенной технологии был взят датасет SkyFusion [16]. В нём присутствует три класса: самолёты, лодки и машины. Объекты описаны в виде координат на наборе изображений размером 640 на 640 пикселей. Пример изображений показан на рис. 2.


Плюсом использования функции дистанции с перебором является отсутствие необходимости большой обучающей выборки, поэтому была взята маленькая выборка: 374 объекта.

В процессе тестирования с помощью разработанной технологии была выполнена классификация 11751 объектов на 448 изображениях. Пример классификации показан на рис. 3. Для каждого объекта визуализируется точность (рис. 4).


Точность классификации рассчитывалась как

$$Accuracy = \frac{\sum_{k=1}^K CX_{k,k}}{\sum_{i=1}^K \sum_{j=1}^K CX_{i,j}}, \quad (3)$$


где  $K$  — число классов;  $CX \in \mathbb{R}^{K \times K}$  — матрица ошибок (confusion matrix);  $CX_{ij}$  — число объектов истинного класса  $i$ , классифи-



а) изображение с лодками



б) изображение с самолётами



в) изображение с транспортом

Рис. 2. Примеры изображений из обучающей выборки

цированных как  $j$ .

В качестве аналога использовалась предобученная нейронная сеть ResNet-18, которая дообучалась на тех же данных, что и предлагаемый классификатор. Результаты показаны в таблице 1. При этом точность для конкретных классов рассчитывалась как процент правильных классификаций по формуле

$$AC = \frac{TP}{COUNT},$$

где  $TP$  — количество правильных классификаций;  $COUNT$  — количество объектов этого класса.

Результаты показывают, что точность предлагаемой технологии близка к нейронной сети, и при этом предсказание не требует высоких вычислительных ресурсов. Однако технология плохо показала себя при классификации класса «лодки». Это связано с тем, что с точки зрения топологии они слишком мало отличаются от иных классов и не обладают достаточным рельефом. При этом нейронная сеть также справилась с этим классом с низкой точностью (53%).

Чтобы исправить данный недостаток, в технологию была внесена доработка. Так как топология ориентируется на контекст, было решено увеличить размер зоны интереса (окна). Т.е., если в датасете указано, что объект расположен в квадрате 20 на 20 пикселей, то баркод будет строиться по квадрату 50 на 50 пикселей (т.е. добавляется по 15 пикселей с каждой стороны). Результаты показаны в таблице 2.




Рис. 3. Пример классификации объекта «самолёт» на снимке №164 из тестовой выборки с помощью предложенной технологии



Рис. 4. Визуализация полученной схожести по формуле (2)

**Таблица 1.** Результат тестирования предложенной технологии и аналога

Классификатор	Точность, %			
	Самолёты	Лодки	Машины	Итог (по (3))
ResNet-18	99	53	97	96
<b>Предложенный подход</b>	98	6	93	91

**Таблица 2.** Сравнение точности при расширении окна

Тип окна	Точность, %			
	Самолёты	Лодки	Машины	Точность
Стандартное	<b>98</b>	6	93	91
Расширенное	93	<b>15</b>	<b>96</b>	<b>93</b>

Результаты показывают, что расширение окна даёт лучшие результаты для большинства классов, однако требуются дополнительные улучшения. Также увеличение окна замедлило время предсказания с 63 сек. до 373 сек. при прочих равных.

### Заключение

Топологическое представление данных является перспективным взглядом на обработку изображений, но всё ещё требует изучения и улучшения. В работе показано, что в задаче мультимасштабной классификации средств передвижения на спутниковых снимках по заранее заданным зонам интереса подход на основе топологического анализа показывает результаты, сопоставимые с нейронной сетью (отставание на 3%), но только для классов, которые подходят с топологической точки зрения. Этот и другие недостатки технологии, такие как линейное время поиска схожего объекта, будут исследованы в дальнейших работах.

### Литература

1. *Chen Ch., Минальд А.А.*, и др. Обнаружение и классификация транспортных средств на снимках сверхвысокого разрешения с помощью нейронных сетей // Журнал прикладной спектроскопии. 2022. Т. 89. №2. С. 275–282.
2. *Chaurasia D., Patro B.D.K.* Detection of objects in satellite and aerial imagery using channel and spatially attentive YOLO-CSL for surveillance // Image and Vision Computing. 2024. Vol. 147. Pp. 105070.
3. *Wang C., Sun P., Yang C., Teng X., Wang R.* AMSA-YOLO: Real-time object detection with adaptive multi-scale attention mechanism // Neural Networks.

2026. Vol. 197. Pp. 108545.

4. *Тарасова В.Ю., Костров Б.В.* Разработка и исследование свёрточных моделей нейронных сетей в задачах поиска похожих изображений // Международный научно-исследовательский журнал. 2025. №6 (156).
5. *Cao Z., Kooistra L., Wang W., Guo L., Valente J.* Real-Time Object Detection Based on UAV Remote Sensing: A Systematic Literature Review // Drones. 2023. Vol. 7. No. 10. Pp. 620.
6. *Wang M., Xu H., Sun Y., Li H., Wang Z., Li Y., Wang R., Zhu X.* EMFNet: An efficient multi-scale fusion network for UAV small object detection // Digital Signal Processing. 2026. Vol. 174. Pp. 105952.
7. *Yang J., Guo F., Niu P.* UAVDet: A CNN–Mamba hybrid network for efficient small object detection in UAV imagery // Computer Vision and Image Understanding. 2026. Vol. 264. Pp. 104637.
8. *Тормозов В.С.* Автоматизированное детектирование и классификация объектов в транспортном потоке на спутниковых снимках города // Программные продукты и системы. 2022. Т. 35. №2. С. 246–254.
9. *Сулицкий М.В., Зеленский И.С., Садовникова Н.П., Финогеев А.Г., Катеринина С.Ю.* Разработка интеллектуальной системы распознавания объектов для решения задач ситуационного управления в городе // Современные наукоемкие технологии. 2023. №7. С. 104–109.
10. *Алексеев В.В., Лакомов Д.В., Шишкин А.А., Аль Маамари Г.* Обработка графических изображений сосредоточенных и площадных объектов // Бизнес-информатика. 2019. Т. 13. № 4. С. 49–59.
11. *Федосов В.П., Ибадов Р.Р., Ибадов С.Р.* Алгоритм сегментации для выделения движущихся объектов на основе реконструкции фона с использованием параметров шумовых характеристик // Журнал радиоэлектроники. 2023. №11.
12. *Dibs H., Hasab H.A., Jaber H.S., Al-Ansair N.* Automatic feature extraction and matching modelling for highly noise near-equatorial satellite images // Innovative Infrastructure Solutions. 2022. Vol. 7. No. 1. Pp. 2.
13. *Пугин Е.В., Жизняков А.Л.* Алгоритмы обработки изображений для обнаружения объектов

с использованием нечётких признаков // Радиотехнические и телекоммуникационные системы. 2020. №2. С. 59-65.

14. Несова А.В., Колесников А.Н. Комбинированный метод сегментации на основе алгоритмов SLIC и Random Forest для классификации древесных пород по данным ДЗЗ. Радиотехнические и телекоммуникационные системы. 2025. №4. С. 5–13.

15. Li X., Ding H., Zhu Y. Wavelet-guided multi-scale edge fusion network for aerial object detection // Digital Signal Processing. 2026. Vol. 173. Pp. 105946.

16. Sudheer K.P. Tiny Object Detection [Электронный ресурс] // Kaggle. URL: <https://www.kaggle.com/datasets/kailaspsudheer/tiny-object-detection> (дата обращения: 11.12.2025).

Поступила 12 декабря 2025 г

English

## USING TOPOLOGICAL ANALYSIS TO CLASSIFY VEHICLES IN SATELLITE IMAGES

**Artyom Vladimirovich Abakumov** — Postgraduate Student, Murom Institute (branch) of the “Vladimir State University named after Alexander and Nikolay Stoletovs”.

**Sergey Vladimirovich Ereemeev** — PhD in Engineering, Associate Professor, Murom Institute<sup>2</sup> (branch) of the “Vladimir State University named after Alexander and Nikolay Stoletovs”.

*Address:* 602264, Russian Federation, Vladimir region, Murom, Orlovskaya str., 23.

*E-mail:* [artem210966@yandex.ru](mailto:artem210966@yandex.ru)

*Abstract:* Unlike text information, extracting semantic information from images is more difficult due to the strong influence of pixel color on one another. This complicates image analysis algorithms for tasks where understanding image content is essential. One such task is classifying objects in an image. Neural network approaches are best suited for this task, as they can establish relationships between pixels, but this requires extensive computational resources and large training data for effective performance. This study proposes an alternative approach that solves the problem of classifying vehicles in satellite images using topological data analysis. The developed technology considers the object's structure and demonstrates high accuracy for aircraft and car classes. The overall classification accuracy of the proposed solution is 93%, which is comparable to the ResNet-18 neural network, which demonstrates an accuracy of 96%. However, the technology requires further development for classifying objects that lack brightness variation, which is partially addressed in this study and will be further explored in future research.

*Keywords:* persistent homology, cellular automata, image processing, satellite images, object detection.

### References

1. Chen Ch., Minald A.A., Bohush R.P., Ma G., Weichen Y., Ablameyko S.V. Detection and Classification of Vehicles in Ultra-High Resolutions Images Using Neural Networks. Zhurnal Prikladnoii Spektroskopii. 2022. Vol 89(2). Pp. 275–282.

2. Chaurasia D., Patro B.D.K. Detection of objects in satellite and aerial imagery using channel and spatially attentive YOLO-CSL for surveillance. Image and Vision Computing. 2024. Vol. 147. Pp. 105070

3. Wang C., Sun P., Yang C., Teng X., Wang R. AMSA-YOLO: Real-time object detection with adaptive multi-scale attention mechanism. Neural Networks. 2026. Vol. 197. Pp. 108545.

4. Tarasova V.Y.I., Kostrov B.V.. Development And Research Of Convolutional Neural Network Models In Similar Image Search Problems. International Research Journal. 2025. No. 6 (156).

5. Cao Z., Kooistra L., Wang W., Guo L., Valente J. Real-Time Object Detection Based on UAV Remote Sensing: A Systematic Literature Review. Drones. 2023. Vol. 7. No. 10. Pp. 620.

6. Wang M., Xu H., Sun Y., Li H., Wang Z., Li Y., Wang R., Zhu X. EMFNet: An efficient multi-scale fusion network for UAV small object detection. Digital Signal Processing. 2026. Vol. 174. Pp. 105952.

7. Yang J., Guo F., Niu P. UAVDet: A CNN–Mamba hybrid network for efficient small object detection in UAV imagery. Computer Vision and Image Understanding. 2026. Vol. 264. Pp. 104637.

8. Tormozov V.S.. Automated detection and classification of objects in the traffic flow on satellite images of the city. Software & Systems. 2022. Vol. 35. No. 2. Pp. 246–254. DOI: 10.15827/0236-235X.138.246-254.

9. *Sulitskiy M.V., Zelenskiy I.S. Sadochnikova N.P., Finogeev A.G., Katerinina S.Y.* Development Of An Intelligent Object Recognition System For Solving The Problems Of Situational Management In The City. Modern high technologies. 2023. No. 7. Pp. 104–109.
10. *Alekseev V.V., Lakomov D.V., Shishkin A.A., Maamari G.A.* Image processing of concentrated and scattered objects. Business Informatics. 2019. Vol. 13. No. 4. Pp. 49–59. DOI: 10.17323/1998-0663.2019.4.49.59
11. *Fedosov V.P., Ibadov R.R., Ibadov S.R.* Segmentation Algorithm For Selecting Moving Objects Based On Background Reconstruction Using Noise Characteristics Parameters. Journal of Radio Electronics. 2023. No. 11.
12. *Dibs H., Hasab H.A., Jaber H.Sl, Al-Ansair N.* Automatic feature extraction and matching modelling for highly noise near-equatorial satellite images. Innovative Infrastructure Solutions. 2022. Vol. 7. No. 1. Pp. 2.
13. *Pugin E.V., Zhiznyakov A.L.* Image processing algorithms for detecting objects using fuzzy features. Radioengineering and telecommunication systems. 2020. No. 2. Pp. 59–65.
14. *Nesova A.V., Kolesenkov A.N.* Combined method of segmentation based on slic and random forest algorithms for classification of wood species based on remote sensing data. Radioengineering and telecommunication systems. 2025. No. 4. Pp. 5–13.
15. *Li X., Ding H., Zhu Y.* Wavelet-guided multi-scale edge fusion network for aerial object detection. Digital Signal Processing. 2026. Vol. 173. Pp. 105946.
16. *Sudheer K.P.* Tiny Object Detection [Electronic source]. Kaggle. URL: <https://www.kaggle.com/datasets/kailaspsudheer/tiny-object-detection> (Access date: 11.12.2025).