

КУПРИЯНОВА Д.В., ПЕРЦЕВ Д.Ю., ТАТУР М.М.

КЛАССИФИКАЦИЯ МЕТОДОВ СЕГМЕНТАЦИИ СНИМКОВ ЗЕМНОЙ ПОВЕРХНОСТИ

Белорусский государственный университет информатики и радиоэлектроники
г. Минск, Республика Беларусь

В данной работе представлена классификация методов сегментации снимков земной поверхности. Рассмотрены такие подходы как сравнение с шаблоном, машинное обучение и глубокие нейронные сети, а также применение знаний об анализируемых объектах. Рассмотрены особенности применения вегетационных индексов для сегментации данных по спутниковым снимкам. Отмечены преимущества и недостатки. Систематизированы результаты, полученные авторами методик, появившихся за последние 10 лет, что позволит заинтересованным быстрее сориентироваться, сформировать идеи для последующих исследований.

Ключевые слова: дистанционное зондирование, глубокое обучение, машинное обучение, сегментация

Введение

Дистанционное зондирование Земли (ДЗЗ) – это процесс удаленного наблюдения за физическими характеристиками зон интереса посредством измерения отраженного электромагнитного излучения с целью их идентификации.

Развитие технологий и их быстрое внедрение в практику привело к постоянно увеличивающемуся объему данных, который необходимо анализировать и обрабатывать. Так, например, объем архива миссий Коперника Европейского космического агентства по состоянию на конец 2022 года составляет приблизительно 39.37 ПБ [1] и продолжает увеличиваться.

Основные исследования по автоматизированной обработке снимков сконцентрированы в следующих областях:

- слияние изображений, при котором происходит объединение снимков, сделанных с помощью разных спектрометров (например, слияние мультиспектральных и панхроматических снимков с разным разрешением или слияние мультиспектральных и гиперспектральных снимков);
- сегментация, при которой каждый пиксель изображения относится к определенному классу;
- поиск изменений на одном и том же участке с течением времени (в иностранных статьях в данном случае часто используют термин *Land Use Land Cover, LULC*).

Запрос в системе поиска научных статей Google Scholar по ключевым словам “segmentation” и “remote sensing” с фильтрацией публикаций за последние 5 лет показал более 70 000 публикаций. Ориентироваться в таком большом объеме информации является трудоемкой задачей. Поэтому в данной работе предпринята попытка систематизации подходов, которые для сегментации снимков земной поверхности за последние 10 лет.

1. Классификация методов сегментации снимков земной поверхности

Несмотря на разнообразие применяемых сенсоров с различными техническими характеристиками, сегментация чаще всего выполняется в видимой части спектра (например, запрос «("multiband segmentation" || "NIR segmentation") "remote sensing"» в *Google Scholar* показал всего 14 публикаций с 2018 года). При этом альтернативные спектральные каналы используются как вспомогательные. Классификация методов сегментации представлена на рисунке 1:

- методы на основе сопоставления с шаблоном (англ. *template matching-based methods*);
- методы, основанные на знаниях (англ. *knowledge-based methods*);
- методы на основе машинного обучения, в т. ч. методы на основе глубоких нейронных сетей.

2. Методы на основе сопоставления с шаблоном

Методы на основе сопоставления с шаблоном являются одним из простейших и старых методов; основаны на применении теории из математической морфологии (чаще всего на преобразовании *hit-or-miss*) и включают два шага (рисунок 2):

- создание шаблона для заданного класса;
- вычисление одной из метрик (например, сумма абсолютных разностей, евклидово расстояние), на основе которой «принимается» решение о соответствии выделенной области классу.

Основные исследования сконцентрированы на создании шаблона и делятся на 2 группы:

- сопоставление с жестким шаблоном (англ. *Rigid Template Matching*), применяющийся для обнаружения конкретных объектов с простым внешним видом и небольшими вариациями (например, дороги и здания) [3–5];

– сопоставление с устойчивым к деформациям шаблоном (англ. *Deformable Template Matching*), применяющийся для обнаружения произвольных объектов со сложным внешним видом (например, самолеты, корабли и др.) [6–9].

В таблице 1 представлены основные результаты, полученные авторами соответствующих статей. Здесь и далее заявленная точность основана на информации, предоставленной авторами соответствующей статьи, и показывает процент верно выделенных объектов от общего числа объектов данного класса. Следует отметить, только *Stankov* со своей командой [3] провел масштабное исследование, оценив

разработанную им методику на 3 тестовых наборах со спутников:

– *GeoEye-1* (200×200 пикселей, получены со спутника 3 июня 2009 года);

– *Ikonos* (200×200 пикселей, получены со спутника 20 мая 2001 года);

– *World View-2* (200×200 пикселей, получены со спутника 30 августа 2010 года).

Также *Chaudhuri* [5] использовал снимки *Ikonos*, однако в статье не представлена информация о корректно выделенных объектах относительно всего тестового набора. Остальные исследователи использовали собственные наборы данных.

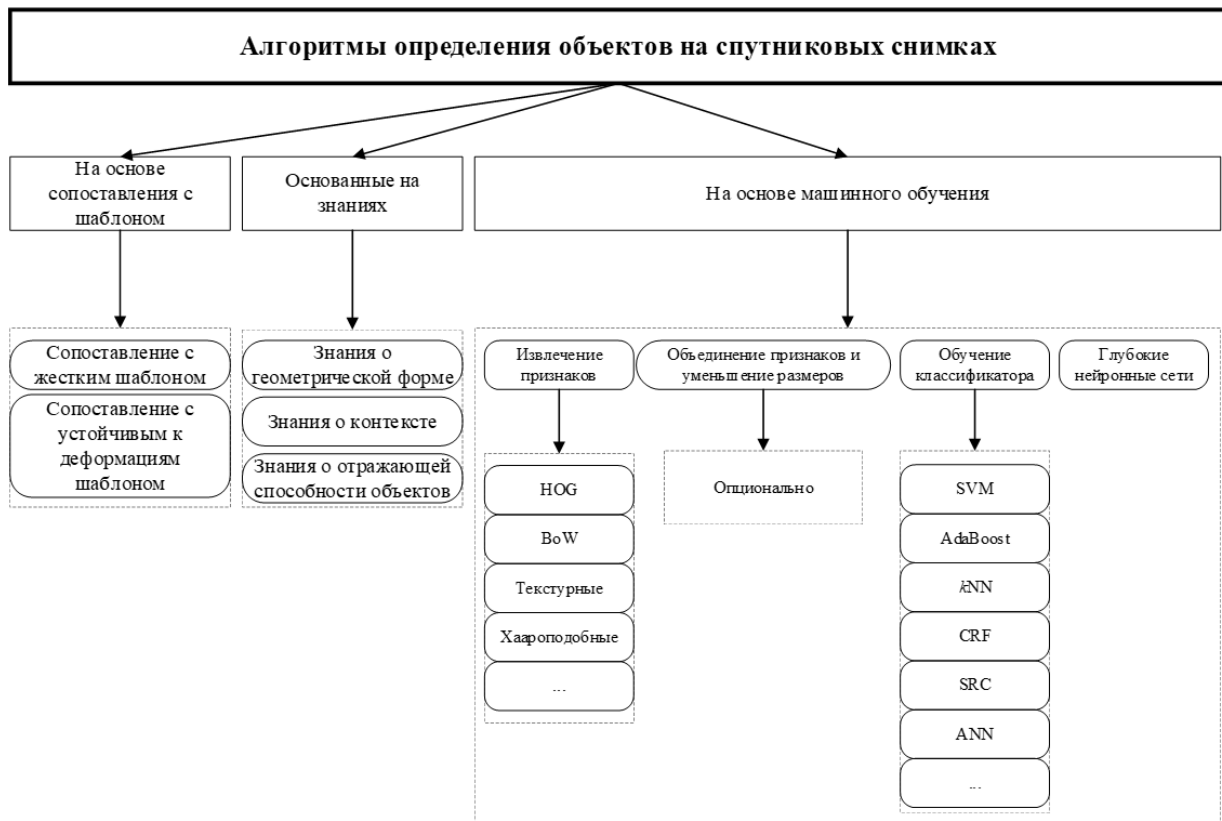


Рисунок 1. Классификация алгоритмов определения объектов на спутниковых снимках


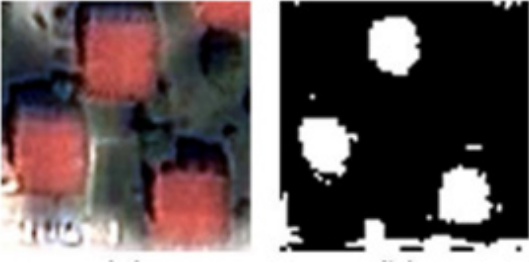
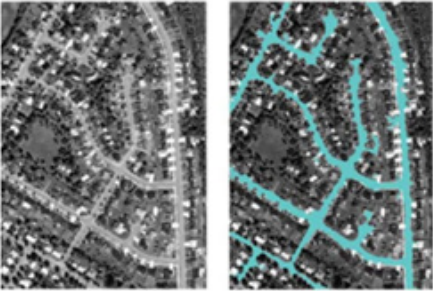
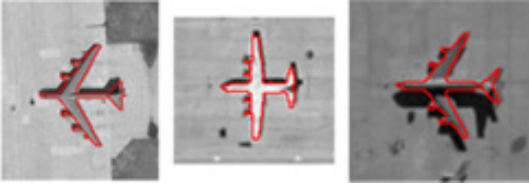




Рисунок 2. Последовательность действий в методах на основе сопоставления с шаблоном

Все представленные методы позволили выявить наличие на изображении заданных классов. Однако из представленных результатов видно, что подходы применимы для выделения области интереса. Их применение в случаях, требующих

формирование точных сегментов затруднительно (например, в работе [3] контуры здания найдены не полностью, в работах [5] и [9] не все дороги обнаружены и присутствуют разрывы на дорогах в [9]).

Результаты сегментации изображений для методов на основе сопоставления с шаблоном

Статья / объект	База снимков	Пример распознавания	Заявленная точность
Stankov [3] здания	Ikonos, GeoEye, World View-2		93 % (Ikonos) 92 % (GeoEye-1) 85 % (World View-2)
Chaudhuri [5] дороги	Ikonos		—
Liu [7] самолеты	авторская		—
Тао [8] аэропорт	авторская		—
Leninisha [9] дороги	авторская		—

Кроме того, методы на основе сопоставления с жестким шаблоном зависят от масштабирования,

угла поворота, чувствительных к точке, с которой велась съемка.

3. Методы, основанные на знаниях

Данные методы являются развитием методов на основе сопоставления с шаблоном и основаны на применении дополнительной информации (рисунок 3). Основной сложностью является формирование знаний и правил (дополнительной информации), в соответствии с которой в дальнейшем будет определяться, о каком объекте идет речь. В целом, анализ статей показывает 3 основных подхода к формированию знаний:

– знания о геометрической форме и радиометрических свойствах объекта [10];

– знания о контексте (например, зная местоположение солнца и координаты съемки можно вычислить угол, под которых отбрасывается тень от высоких объектов) [11, 12];

– знания об отражающей способности объектов.

В таблице 2 обобщены основные результаты, полученные авторами соответствующих работ. Из проанализированных работ только команда *Ali Ok* использовала спутниковые снимки, полученные со спутника *GeoEye-1*, и оценила корректность полученных результатов на всем множестве снимков.

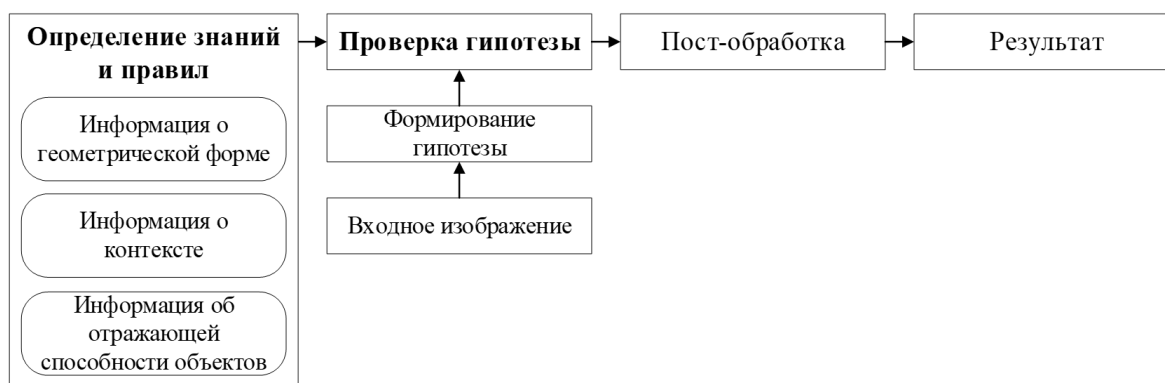
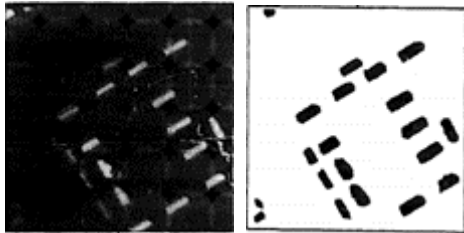
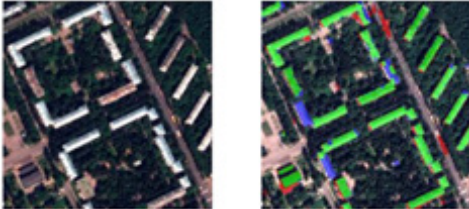



Рисунок 3. Последовательность действий в методах определения объектов, основанных на знаниях

Таблица 2

Результаты сегментации изображений для методов, основанных на знаниях

Статья / объект	База снимков	Пример распознавания	Заявленная точность
Weidner [10] здания	авторская		–
Ok [11] здания	GeoEye-1		80,3 % при среднеквадратическом отклонение ~11 %
Аксау [12] здания	авторская		–

Наиболее перспективным в данной группе методов является применение знаний об отражающей способности объектов и, в частности, информации об вегетационных индексах.

Вегетационный индекс – метрика, используемая для оценки различных параметров в природопользовании (в т. ч. в сельском хозяйстве) на основе информации из различных спектральных каналов.

С их помощью можно:

- оценить преобладание зеленых растений (например, с помощью метрик *NDVI* [13], *EVI* [14]), снежных и водных покровов (например, метрики *NDSI* [15] и *NDWI* [16] соответственно);

- исследовать эффективность применения удобрений (метрика *GCI* [17]) и обнаруживать заболеваемость растений (метрика *SIP1* [18]);

- обнаруживать активные лесные пожары (метрика *NBR* [19]).

Однако, несмотря на то, что для их применения достаточно наличие соответствующего спектрального канала, отсутствует необходимость в подготовке и разметке данных, в работах [20–22] было показано, что данные метрики являются не точными и, как результат, не могут применяться как самостоятельное решение в задачах сегментации. Тем не менее, в ряде работ (например, [3] и [11]) данные метрики используются для уточнения и корректировки результата.

4. Методы на основе машинного обучения и глубоких нейронных сетей

Развитие методов машинного обучения и, особенно, развитие классификаторов и способов представления признаков, привело к существенному

прогрессу. Обобщенная схема работы методов данной группы представлена на рисунке 4 [23–26].

С ростом популярности глубокого обучения было разработано множество моделей нейронных сетей для сегментации. Появление в 2017 году полносверточной сети (англ. *Fully Convolutional Network*) [27] позволило применить методики из глубокого обучения к задаче сегментации данных ДЗЗ. В дальнейшем появилось множество развитий данного подхода [28, 29], а также попытки применения более современных архитектур глубоких нейронных сетей (на рисунке 5 представлены актуальные архитектуры и примеры моделей глубоких нейронных сетей):

- на основе механизма привлечения внимания (англ. *attention mechanism*) [35–38];

- на основе многомасштабной стратегии (англ. *multi-scale strategy*) [39];

- на основе трансформеров [40, 41];

- на основе генеративно-сопоставительных сетей [42].

В таблице 3 обобщены основные результаты, полученные авторами соответствующих работ. Для обучения нейронной сети в большинстве рассмотренных моделей использовались *ISPRS Potsdam* (38 снимков с разрешением 6000×6000 пикселей, пространственное разрешение – 5 см. на 1 пиксель) и *ISPRS Vaihingen* (33 снимка с разрешением 2500×2000 пикселей, пространственное разрешение – 9 см. на 1 пиксель). В качестве метрик для обобщения результата использовались среднее значение F_1 (mF_1), *mIoU* (англ. *mean intersection over union*) и *OA* (общая точность, англ. *Overall Accuracy*).

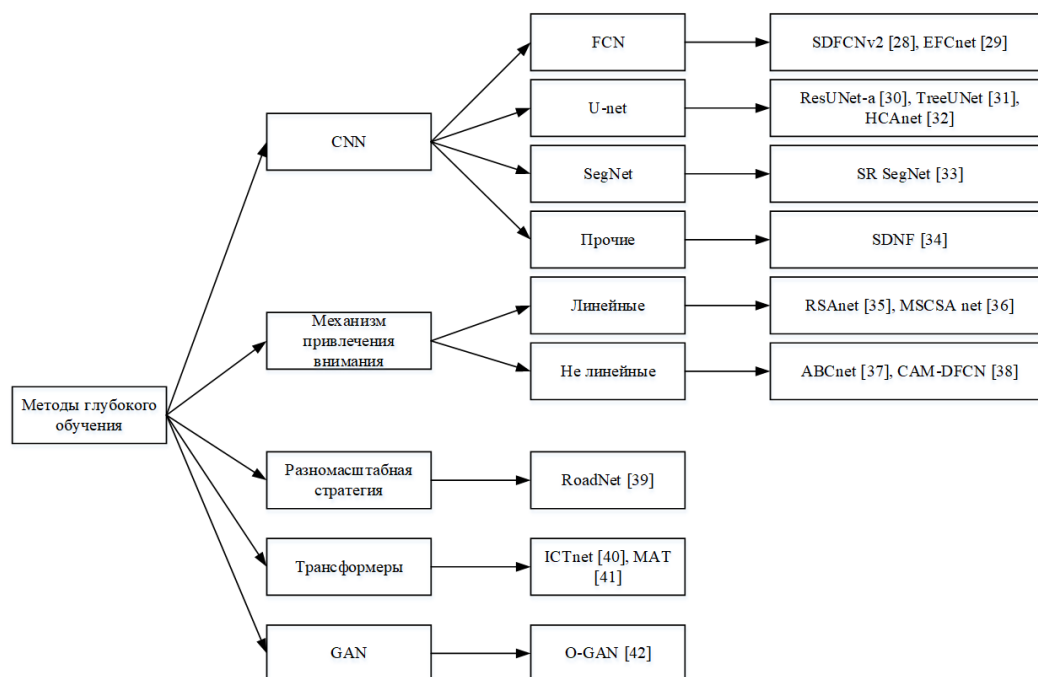


Рисунок 5. Обобщенная схема работы методов, основанных на применении алгоритмов машинного обучения




Рисунок 4. Последовательность действий в методах определения объектов, основанных на знаниях

Таблица 3

Результаты сегментации изображений для методов на основе машинного обучения и глубоких нейронных сетей

Метод	Модель	База снимков	База снимков 1			База снимков 2		
			mF ₁ , %	mIoU, %	OA, %	mF ₁ , %	mIoU, %	OA, %
Машинное обучение	[23]	Google Maps	94.08	–	–	–	–	–
	[24]	Карты 6 городов	94.8	–	–	–	–	–
CNN	[28]	Potsdam	–	67.82	85.03	–	–	–
	[29]	Potsdam, Vaihingen	79.74	65.7	80.72	81.87	70.14	85.46
	[30]	Potsdam	91.5	–	–	–	–	–
	[31]	Potsdam, Vaihingen	92	–	–	89.3	–	–
	[32]	Potsdam, Vaihingen	87.09	78.92	90.78	89.02	81.03	90.33
	[33]	авторский	99.49	93.04	–	–	–	–
Механизм привлечения внимания	[34]	Potsdam, Vaihingen	93.4	84.6	–	90.0	89.5	–
	[35]	DroneDeploy, Chreos	–	62.92	–	–	87.32	–
	[36]	Potsdam, Vaihingen	83.7	71.9	–	83.0	70.9	–
	[37]	Potsdam	92.7	86.5	91.3	–	–	–
Многомасштабная стратегия	[38]	Potsdam, Vaihingen	89.43	–	90.26	88.55	–	90.41
	[39]	CNDS	91.3	90.2	–	–	–	–
Трансформеры	[40]	Potsdam, Vaihingen	93	–	91.57	92.34	–	90.14
	[41]	Potsdam, Vaihingen	91.59	84.82	–	88.7	79.93	–

Заключение

В статье представлена авторская классификация методов сегментации снимков ДЗЗ, обобщены результаты, полученные авторами методик. Несмотря на то, что для каждой группы методов были найдены статьи, появившиеся за последние 10 лет, следует отметить, что акцент в исследованиях смещается в пользу применения глубоких нейронных сетей. Это связано с трудностями, возникающими при создании качественного шаблона, с необходимостью применения нескольких методов в случае выделения более одного класса. С другой стороны, результаты применения разных архитектур глубо-

ких нейронных сетей также выявили ряд проблем, которые необходимо решать в дальнейшем:

– в большинстве тестов используется всего 2 тестовых набора с высоким пространственным разрешением. Исследований по применению указанных методов к «сырым» данным, полученным со спутников ДЗЗ (например, *Sentinel-2*, *LandSat-8*) не выявлено;

– требования к вычислительным ресурсам для обучения и, что более существенно, для практического применения высоки и предполагают, как минимум, применение качественной дискретной видеокарты, что также может являться преградой для практического применения в некоторых задачах.

REFERENCES

1. Copernicus Sentinel Data Access: Annual Report, 2022 [Electronic resource]. Access mode: https://scihub.copernicus.eu/twiki/pub/SciHubWebPortal/AnnualReport2022/COPE-SERCO-RP-23-1493_SentinelDataAccessAnnual_Report_2022.pdf. Accessed: 19.11.2023.
2. **Cheng G., Han Junwei.** A survey on object detection in optical remote sensing images. *ISPRS Journal of Photogrammetry and Remote Sensing*. 2016. Vol. 117. Pp. 11-28. doi: 10.1016/j.isprsjprs.2016.03.014
3. **Stankov K., He Dong-Chen.** Detection of Buildings in Multispectral Very High Spatial Resolution Images Using the Percentage Occupancy Hit-or-Miss Transform. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. 2014. Vol. 7. Issue 10. Pp. 4069-4080. doi: 10.1109/JSTARS.2014.2308301
4. **Weber J., Lefèvre S.** Spatial and spectral morphological template matching. *Image and Vision Computing*. 2012. Vol. 30. Issue 12. Pp. 934-945. doi: 10.1016/j.imavis.2012.07.002
5. **Chaudhuri D., Kushwaha N., Samal A.** Semi-Automated Road Detection From High Resolution Satellite Images by Directional Morphological Enhancement and Segmentation Techniques. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. 2012. Vol. 5. Issue 5. Pp. 1538-1544. doi: 10.1109/JSTARS.2012.2199085
6. **Lin Y., He H., Yin Z., Chen F.** Rotation-invariant object detection in remote sensing images based on radial-gradient angle. *IEEE Geoscience and Remote Sensing Letters*. 2015. Vol. 12. Issue 4. Pp. 746-750. doi: 10.1109/LGRS.2014.2360887
7. **Liu G., Sun X., Fu K., Wang H.** Interactive geospatial object extraction in high resolution remote sensing images using shape-based global minimization active contour model. *Pattern Recognition Letters*. 2013. Vol. 34. Issue 10. Pp. 1186-1195. doi: 10.1016/j.patrec.2013.03.031
8. **Tao C., Tan Y., Cai H., Tian J.** Airport detection from large IKONOS images using clustered SIFT keypoints and region information. *IEEE Geoscience and Remote Sensing Letters*. 2011. Vol. 8. Issue 1. Pp. 128-132. doi: 10.1109/LGRS.2010.2051792
9. **Leninisha S., Vani K.** Water flow based geometric active deformable model for road network. *ISPRS Journal of Photogrammetry and Remote Sensing*. 2015. Vol. 102. Pp. 140-147. doi: 10.1016/j.isprsjprs.2015.01.013
10. **Weidner U., Förstner W.** Towards automatic building extraction from high-resolution digital elevation models. *ISPRS Journal of Photogrammetry and Remote Sensing*. 1995. Vol. 50. Issue 4. Pp. 38-49. doi: 10.1016/0924-2716(95)98236-S
11. **Ok A.O., Senaras C., Yuksel B.** Automated detection of arbitrarily shaped buildings in complex environments from monocular VHR optical satellite imagery. *IEEE Transactions on Geoscience and Remote Sensing*. 2013. Vol. 51. Issue 3. Pp. 1701-1717. doi: 10.1109/TGRS.2012.2207123
12. **Akçay H.G., Aksoy S.** Building detection using directional spatial constraints. *IEEE International Geoscience and Remote Sensing Symposium*. 2010. Pp. 1932-1935. doi: 10.1109/IGARSS.2010.5652842
13. **Rouse J.W.** [et al.] Monitoring vegetation systems in the Great Plains with ERTS. *Third Earth Resources Technology Satellite-1 Symposium*. Vol. 1: Technical Presentations, section A. 1973. NASA. Pp. 309-317.
14. **Huete A.** [et al.] Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sensing of Environment*. 2002. Vol. 83. Issue 1-2. Pp. 195-213. doi: 10.1016/S0034-4257(02)00096-2
15. **Riggs G., Hall D., Salomonson V.** A Snow Index for the Landsat Thematic Mapper and Moderate Resolution Imaging Spectrometer. *Proceedings of IGARSS'94 – 1994 IEEE International Geoscience and Remote Sensing Symposium*. 1994. Pasadena, CA, USA. Pp. 1942-1944. doi: 10.1109/IGARSS.1994.399618
16. **McFeeters S.** The Use of Normalized Difference Water Index (NDWI) in the Delineation of Open Water Features. *International Journal of Remote Sensing*. 1996. Vol. 17. Pp. 1425-1432. doi: 10.1080/01431169608948714
17. **Gitelson A., Kaufman Y., Merzlyak M.** Use of a green channel in remote sensing of global vegetation from EOS-MODIS. *Remote Sensing of Environment*. 1996. Vol. 58. Issue 3. Pp. 289-298. doi: 10.1016/S0034-4257(96)00072-7

18. **Penuelas J., Baret F., Filella I.** Semi-Empirical Indices to Assess Carotenoids/Chlorophyll-a Ratio from Leaf Spectral Reflectance. *Photosynthetica*. 1995. Vol. 31. Pp. 221-230.
19. **Key C., Benson N.** Landscape Assessment: Remote Sensing of Severity, the Normalized Burn Ratio; and Ground Measure of Severity, the Composite Burn Index. FIREMON: Fire Effects Monitoring and Inventory System, RMRS-GTR, Ogden, UT: USDA Forest Service. 2005.
20. **Huang S.** [et al.] A commentary review on the use of normalized difference vegetation index (NDVI) in the era of popular remote sensing. *Journal of Forestry Research*. 2021. Vol. 32. doi: 10.1007/s11676-020-01155-1
21. **Miura T.** [et al.] An error and sensitivity analysis of atmospheric resistant vegetation indices derived from dark target-based atmospheric correction. *Remote Sensing of Environment*. 2001. Vol. 78. Issue 3. Pp. 284-298. doi: 10.1016/S0034-4257(01)00223-1
22. **Matsushita B.** [et al.] Sensitivity of the Enhanced Vegetation Index (EVI) and Normalized Difference Vegetation Index (NDVI) to Topographic Effects: A Case Study in High-density Cypress Forest. *Sensors*. 2007. Vol. 7. Pp. 2636-2651. doi: 10.3390/s7112636
23. **Liu L., Shi Z.** Airplane detection based on rotation invariant and sparse coding in remote sensing images. *Optik*. 2014. Vol. 125. Issue 18. Pp. 5327-5333. doi: 10.1016/j.ijleo.2014.06.062
24. **Li E.** [et al.] Robust Rooftop Extraction From Visible Band Images Using Higher Order CRF. *IEEE Transactions on Geoscience and Remote Sensing*. 2015. Vol. 53. Issue 8. Pp. 4483-4495. doi: 10.1109/TGRS.2015.2400462
25. **Yao X.** [et al.] A coarse-to-fine model for airport detection from remote sensing images using target-oriented visual saliency and CRF. *Neurocomputing*. 2015. Vol. 164. Pp. 162-172. doi: 10.1016/j.neucom.2015.02.073
26. **Zhang W.** [et al.] A generic discriminative part-based model for geospatial object detection in optical remote sensing images. *ISPRS Journal of Photogrammetry and Remote Sensing*. 2015. Vol. 99. Pp. 30-44. doi: 10.1016/j.isprsjprs.2014.10.007
27. **Long J.** [et al.] Fully convolutional networks for semantic segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2017. Vol. 39. Issue 4. Pp. 640-651. doi: 10.1109/TPAMI.2016.2572683
28. **Chen G.** [et al.] SDFCNv2: an improved FCN framework for remote sensing images semantic segmentation. *Remote Sensing*. 2021. Vol. 13. doi: 10.3390/rs13234902
29. **Chen L.** [et al.] EFCNet: ensemble full convolutional network for semantic segmentation of high-resolution remote sensing images. *IEEE Geoscience and Remote Sensing Letters*. Vol. 19. doi: 10.1109/LGRS.2021.3076093
30. **Foivos I.** [et al.] ResUNet-a: a deep learning framework for semantic segmentation of remotely sensed data. *ISPRS Journal of Photogrammetry and Remote Sensing*. 2020. Vol. 162. Pp. 94-114. doi: 10.1016/j.isprsjprs.2020.01.013
31. **Yue K.** [et al.] TreeUNet: adaptive tree convolutional neural networks for subdecimeter aerial image segmentation. *ISPRS Journal of Photogrammetry and Remote Sensing*. 2019. Vol. 156. Pp. 1-13. doi: 10.1016/j.isprsjprs.2019.07.007
32. **Bai H.** [et al.] HCANet: a hierarchical context aggregation network for semantic segmentation of high-resolution remote sensing images. *IEEE Geoscience and Remote Sensing Letters*. 2021. Vol. 19. doi: 10.1109/LGRS.2021.3063799
33. **Weng L.** [et al.] Water areas segmentation from remote sensing images using a separable residual segnet network. *ISPRS International Journal of Geo-Information*. 2020. Vol. 9. doi: 10.3390/ijgi9040256
34. **Mi L., Chen Z.** Superpixel-enhanced deep neural forest for remote sensing image semantic segmentation. *ISPRS Journal of Photogrammetry and Remote Sensing*. 2020. Vol. 159. Pp. 140-152. doi: 10.1016/j.isprsjprs.2019.11.006
35. **Zhao D.** [et al.] Semantic segmentation of remote sensing image based on regional selfattention mechanism. *IEEE Geoscience and Remote Sensing Letters*. Vol. 19. doi: 10.1109/LGRS.2021.3071624
36. **Liu K.-H., Lin B.-Y.** MSCSA-Net: Multi-Scale Channel Spatial Attention Network for Semantic Segmentation of Remote Sensing Images. *Applied Sciences*. 2023. Vol. 13. Issue 17. doi: 10.3390/app13179491
37. **Li R., Duan C.X.** ABCNet: attentive bilateral contextual network for efficient semantic segmentation of fine-resolution remotely sensed imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*. 2021. Vol. 181. Pp. 84-98. doi: 10.1016/j.isprsjprs.2021.09.005
38. **Luo H.** [et al.] High-resolution aerial images semantic segmentation using deep fully convolutional network with channel attention mechanism. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. 2019. Vol. 12. Issue 9. Pp. 3492-3507. doi: 10.1109/JSTARS.2019.2930724
39. **Liu Y.** [et al.] RoadNet: learning to comprehensively analyze road networks in complex urban scenes from high-resolution remotely sensed images. *IEEE Transactions on Geoscience and Remote Sensing*. 2019. Vol. 57. Issue 4. Pp. 2043-2056. doi: 10.1109/TGRS.2018.2870871
40. **Li X.** [et al.] Encoding contextual information by interlacing Transformer and convolution for remote sensing imagery semantic segmentation. *Remote Sensing*. 2022. Vol. 14. doi: 10.3390/rs14164065
41. **Zhao X.** [et al.] Memory-augmented Transformer for remote sensing image semantic segmentation. *Remote Sensing*. 2021. Vol. 13. doi: 10.3390/rs13224518
42. **Sun S.** [et al.] Semantic segmentation for buildings of large intra-class variation in remote sensing images with O-GAN. *Remote Sensing*. 2021. Vol. 13. doi: 10.3390/rs13030475

KYPRIYANOVA DZIANA V., PERTSAU DMITRY Y., TATUR MIKHAIL M.

CLASSIFICATION OF EARTH SURFACE IMAGE SEGMENTATION METHODS

*Belarusian State University of Informatics and Radioelectronics
Minsk, Republic of Belarus*

The classification of methods for land surface image segmentation is presented in the paper. Such approaches as template matching, machine learning and deep neural networks, as well as application of knowledge about analyzed objects are considered. Peculiarities of vegetation indices application for satellite images data segmentation are considered. Advantages and disadvantages are noted. The results obtained by the authors of the methods that have appeared over the last 10 years are systematized, which will allow those interested to get oriented faster and form ideas for further research.

Keywords: *remote sensing, machine learning, semantic segmentation, vegetation indices*

Куприянова Д.В., старший преподаватель, аспирант, кафедра электронных вычислительных машин, Белорусский государственный университет информатики и радиоэлектроники.

Kupriyanova D., Senior Lecturer, PhD Student, Electronic Computing Machines Department, Belarusian State University of Informatics and Radioelectronics.

E-mail: kupriyanova@bsuir.by

Перцев Д.Ю., кандидат технических наук, доцент, доцент кафедры электронных вычислительных машин, Белорусский государственный университет информатики и радиоэлектроники.

Pertsau D., PhD, Associate Professor, Associate Professor of Electronic Computing Machines Department, Belarusian State University of Informatics and Radioelectronics.

E-mail: pertsev@bsuir.by

Татур М.М., доктор технических наук, профессор, профессор кафедры электронных вычислительных машин, Белорусский государственный университет информатики и радиоэлектроники.

Tatur M., Doctor of Science, Professor, Professor of Electronic Computing Machines Department, Belarusian State University of Informatics and Radioelectronics.

E-mail: tatur@bsuir.by