

Двадцать третья международная конференция «Современные проблемы  
дистанционного зондирования Земли из космоса»

10-14 ноября 2025 г., ИКИ РАН

# Возможности нейронной сети YOLOv11 для задачи автоматической сегментации просек под ЛЭП

Бахрамхан Я.О., НИУ ВШЭ, ИКИ РАН

Ермаков Д.М., ИКИ РАН, ФИРЭ им. В.А. Котельникова РАН

Подольская Е.С., ЦЭПЛ РАН им. А.С. Исаева, НИУ ВШЭ



# Актуальность исследования

Дистанционные способы мониторинга способны предоставлять своевременную информацию про состояние просек под линиями электропередач (ЛЭП). Однако он невозможен без наличия актуальных данных о расположении просек. Границы просек под ЛЭП можно получить методом ручного дешифрирования на космических снимках, однако такой метод требует значительных временных затрат, особенно для больших массивов данных дистанционного зондирования. Нейросетевые технологии, в частности сверточная нейросеть YOLO (англ. You Only Look Once), предлагают более масштабируемый и точный поиск объектов на снимках, поэтому они успешно заменяют ручные способы дешифрирования.




# Выбор территории и сбор данных

Для сбора данных выбраны шесть административных районов Восточной Сибири – Мотыгинский, Богучанский и Северо-Енисейский районы Красноярского края, а также Усть-Илимский, Нижнеилимский и Усть-Кутский районы Иркутской области. Снимки – Sentinel-2 разрешением 10 метров.

Для набора данных в процессе скачивания применялась фильтрация:

- дата получения: июнь-июль 2024 г.
- процент облачности: < 5%
- каналы: синий, зеленый, красный, ближний инфракрасный (B8) и коротковолновый инфракрасный (B11).

Размер снимков – 256\*256 пикселей.






# Ручная разметка снимков Sentinel-2

В ходе предварительного анализа космических снимков и их спектральных каналов определены следующие классы объектов для сегментации изображений:

- Просека под ЛЭП
- Низкорослая растительность
- Облака

Разметка изображений Sentinel-2 проводилась в программе DigitalSreeni Image Annotator. Всего размечено 1396 изображений.

Среди каналов на вход в YOLO выбраны красный, ближний инфракрасный и коротковолновый инфракрасный. В частности последний канал подходит для выделения просек под ЛЭП (Бахрамхан и др., 2025). Нейросеть YOLO необходимо дообучить, чтобы она адаптировала веса под каналы инфракрасного спектра.




# Аугментация набора данных Sentinel-2

Пары изображений синтеза Red-NIR-SWIR и их масок случайным образом разделены три выборки. 596 снимков оказались в обучающей выборке, 400 снимков – в валидационной и оставшиеся 400 снимков – в тестовой выборке.

Распределение масок по классам в обучающей выборке крайне неравномерно. Это может привести к тому, что класс низкорослой растительности будет переоценен нейросетью. Поэтому для обучающей выборки применена аугментация изображений с редкими классами – просека под ЛЭП и облака. Для изображений с редкими классами создано пять аугментированных копий.


Класс	Число меток до аугментации	Число меток после аугментации
Просека под ЛЭП	415	1460
Низкорослая растительность	1012	1012
Облака	239	1149





# Аугментация набора данных Sentinel-2


1. горизонтальное зеркальное отражение;
2. вертикальное зеркальное отражение;
3. транспонирование;
4. сдвиг всего изображения;
5. аффинное преобразование (одновременный поворот, масштабирование и сдвиг одной стороны изображения) с сохранением соотношения ширины и высоты снимка;
6. морфологическая операция дилиации;
7. случайное изменение контраста;
8. случайное изменение оттенка, насыщенности и яркости;
9. размытие.




После аугментации количество снимков в обучающей выборке увеличилось до **1646**.

Теперь размер всего набора данных составляет **2446** изображений.


HorizontalFlip




VerticalFlip




Transpose




ShiftScaleRotate



Affine



Morphological




BrightnessContrast



HueSaturationValue



Blur



# Результаты обучения

Обучение нейросети остановилось вовремя – на последних эпохах значения функций потерь для валидационной выборки не возросли, когда для обучающей выборки они продолжали снижаться. Поэтому нейросеть YOLO не переобучилась.

Average Precision (AP) – способность модели хорошо отделять объекты определенного класса от объектов других классов, учитывая и точность (Precision), и полноту (Recall). Высокое значение AP достигнуто у класса облаков, в то время как у низкорослой растительности оно самое низкое. Класс просеки обладает средним между двумя остальными классами значением метрики, равным 0,652. Среднее значение AP равно 0,696, что соответствует средней степени делимости классов друг от друга.

Класс	Значение Average Precision
Просека под ЛЭП	0,652
Низкорослая растительность	0,596
Облака	0,84
Все классы	0,696

$$Precision_i = \frac{TP_i}{TP_i + FP_i}$$

$$Recall_i = \frac{TP_i}{TP_i + FN_i}$$

$TP_i$  – число объектов класса  $i$ , правильно классифицированных как  $i$

$FP_i$  – число объектов других классов, ошибочно классифицированных как  $i$

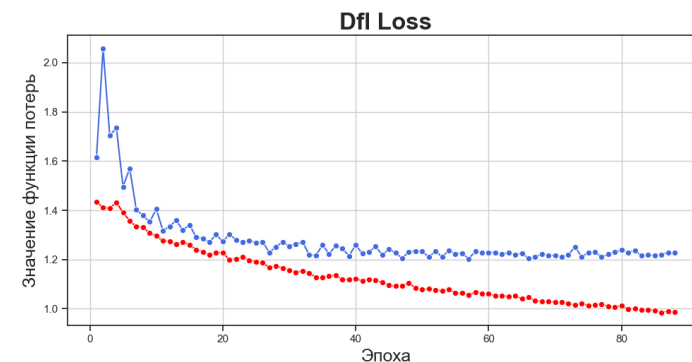



$FN_i$  – число объектов класса  $i$ , ошибочно классифицированных как другой класс

Box Loss – потери определения ограничивающего прямоугольника выделенного объекта

Seg Loss – потеря сегментации маски объекта

Cls Loss – потери определения класса объекта

Dfl Loss – распределительная фокусная потеря

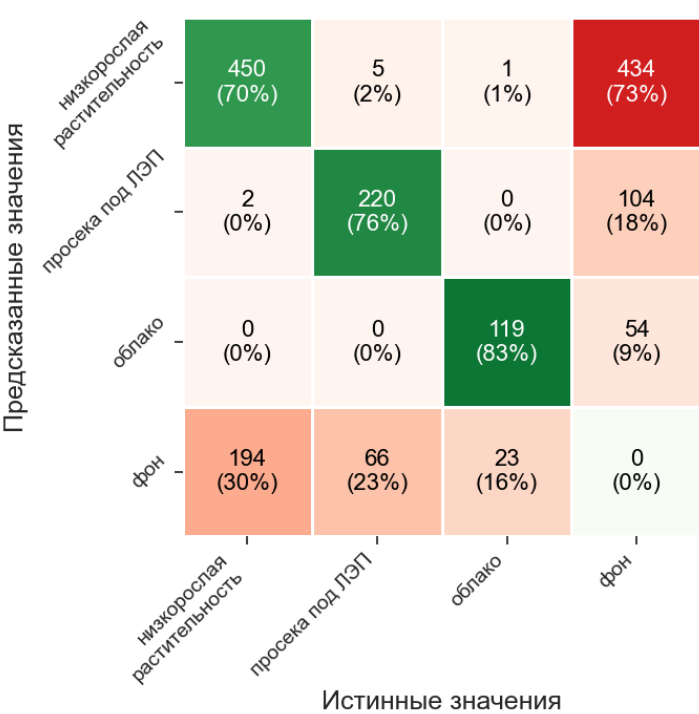




# Результаты обучения


По матрице несоответствий, почти четверть просек под ЛЭП (23%) выделены как фон. Скорее всего, это узкие просеки, которые по форме и яркости напоминают автодороги, а также расположенные на краях изображений просеки. Среди объектов фона, выделенных как просеки, есть такие, которые не расположены под ЛЭП, например просеки под дорогами.

По значениям метрик Intersection over Union (IoU) и коэффициента Дайса (Dice) можно сказать, что нейросеть YOLO успешно находит область, в которой находится распознанный объект, однако нейросетевой алгоритм совершает ошибки в выделении точных границ. Заниженное среднее значение метрик для просек может объясняться тем, что многие просеки выделяются фрагментарно либо не выделяются нейросетью вовсе



$$IoU = \frac{|A \cap B|}{|A \cup B|} \quad Dice = \frac{2 \times |A \cap B|}{|A| + |B|}$$

Класс	Среднее значение IoU	Среднее значение Dice
Просека под ЛЭП	0,725	0,83
Низкорослая растительность	0,706	0,809
Облако	0,705	0,816





# Сравнение с аналогичными исследованиями

Исследование	Объект исследования	Размер набора снимков	Решаемая задача	Использованные нейросети	Результаты
Dasenbrock et al. (2021)	просеки под трубопроводами в Британии и Северной Германии на снимках Landsat 5	Обучающая выборка: 324 снимка Тестовая выборка: 33 снимка	Сегментация	Нейросеть U-net	Средний IoU для обучающей: $0.71 \pm 0.02$ Средний IoU для тестовой: $0.56 \pm 0.04$
Jiang et al. (2020)	небольшие и узкие прямоугольные объекты (дороги, мосты и т.д.) на спутниковых снимках Google Earth	2413 изображений, 34 146 объектов в 7 классах 70% – обучающая выборка, 30% – тестовая выборка	Обнаружение	Авторская нейронная сеть, сочетающая двухконтурную архитектуру и стратегию адаптивной локализации	mAP = 79.4% (трёхканальные RGB изображения). mAP = 77.8% (одноканальные grayscale изображения)
Chang et al. (2023)	наземные нефте- и газопроводы в российской части Арктики из WayBack Imagery	Обучающая выборка: 1 200 снимков Тестовая выборка: 188 снимков	Сегментация	<ul style="list-style-type: none"> <li>FCN (Fully Convolutional Network)</li> <li>U-Net</li> </ul>	Для лучшей модели – U-net: MIoU: 0,894 Precision: 0,94 Recall: 0,936
Arora et al. (2023)	Дороги из наборов данных аэрофотоснимков Massachusetts Road database (MRD) and Ottawa Road database (ORD)	MRD: 1108 для обучения, 14 для валидации, 49 для теста ORD: 20 для теста	Сегментация	Нейросеть со взвешенными пропускными соединениями на основе дробных производных	IoU: 0,787 для MRD и 0,9062 для ORD
Cano-Solis et al. (2023)	линии электропередач и участки зарастания на снимках с БПЛА в Энвигадо, Колумбия	6196 снимков (3724 получены после геометрической аугментации, 3192 – после цветовой аугментации)	Сегментация	<ul style="list-style-type: none"> <li>U-Net с энкодером VGG-16 для выделения растительности</li> <li>DeepLabV3 для выделения ЛЭП</li> </ul>	Растительность: IoU = 0.77 Линии электропередач: IoU = 0.64

# Заключение

Обучение нейронной сети YOLO для поиска просек под ЛЭП проведено успешно – нейросеть не только правильно относит большинство просек в их класс, но и четко выделяет их границы. При этом YOLO реализована в библиотеке на языке Python, что делает обученную нейросеть легко встраиваемой в графический интерфейс, например, плагина QGIS. Эти факторы делают данную модель пригодной для использования на практике для автоматического выделения просек под ЛЭП, несмотря на некоторые ошибки, связанные с низким пространственным разрешением снимков Sentinel-2, схожестью просеки под ЛЭП с остальными видами просек и другими ошибками.

Для улучшения точности алгоритма можно рассматривать увеличение существующего набора данных через отбор снимков на новые территории как в таежной зоне, так и за ее пределами. Это способствует большему разнообразию объектов, представленных в трех классах, что делает нейросеть более универсальной для применения. Помимо расширения набора изображений, рассматривается обучение других нейросетевых моделей, которые с наибольшей точностью способны выделять узкие и вытянутые объекты подобно просекам.

Работа выполнена в рамках государственного задания ИКИ РАН (тема «Мониторинг», госрегистрация № 122042500031-8) и государственного задания ЦЭПЛ РАН по теме «Биоразнообразие и экосистемные функции лесов» (регистрационный номер НИОКТР 124013000750-1).



# Список литературы:

1. Dasenbrock, J.; Pluta, A.; Zech, M.; Medjroubi, W. Detecting Pipeline Pathways in Landsat 5 Satellite Images With Deep Learning. *Energies* 2021, 14, 5642. <https://doi.org/10.3390/en14185642>
2. Jiang, S., Yao, W., Wong, M. S., Li, G., Hong, Z., Kuc, T. Y., & Tong, X. (2020). An optimized deep neural network detecting small and narrow rectangular objects in Google Earth images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13, 1068–1081.
3. Chang, H., Bai, L., Wang, Z., Wang, M., Zhang, Y., Tao, J., & Chen, L. (2023). Detection of over-ground petroleum and gas pipelines from optical remote sensing images. In L. Bruzzone, & F. Bovolo (Eds.), *Image and Signal Processing for Remote Sensing XXIX: proceedings (Proceedings of SPIE; Vol. 12733)*. SPIE – The International Society for Optical Engineering. <https://doi.org/10.1117/12.2683053>
4. Arora, S., Suman, H. K., Mathur, T., Pandey, H. M., & Tiwari, K. (2023). Fractional derivative based weighted skip connections for satellite image road segmentation. *Neural Networks*, 161, 142–153.
5. Cano-Solis, M.; Ballesteros, J.R.; Sanchez-Torres, G. VEPL-Net: A Deep Learning Ensemble for Automatic Segmentation of Vegetation Encroachment in Power Line Corridors Using UAV Imagery. *ISPRS Int. J. Geo-Inf.* 2023, 12, 454. <https://doi.org/10.3390/ijgi12110454>
6. Бахрамхан, Я. О., Ермаков, Д. М., & Подольская, Е. С. (2025). Автоматическое детектирование просек под линиями электропередач на снимках Sentinel-2 с помощью методов машинного обучения и компьютерного зрения. *Современные Проблемы Дистанционного Зондирования Земли Из Космоса*, 22(4), 11–26. <https://doi.org/10.21046/2070-7401-2025-22-4-11-26>