Определение культуры сельскохозяйственных растений по данным дистанционного зондирования с применением методов искусственного интеллекта^{*}

О. А. Митрофанова¹, С. Нин¹, Е. П. Митрофанов^{1,2}

¹ Санкт-Петербургский государственный университет,

Российская Федерация, 199034, Санкт-Петербург, Университетская наб., 7–9

² Агрофизический научно-исследовательский институт,

Российская Федерация, 195220, Санкт-Петербург, Гражданский пр., 14

Для цитирования: Митрофанова О. А., Нин С., Митрофанов Е. П. Определение культуры сельскохозяйственных растений по данным дистанционного зондирования с применением методов искусственного интеллекта // Вестник Санкт-Петербургского университета. Прикладная математика. Информатика. Процессы управления. 2025. Т. 21. Вып. 1. С. 112–121. https://doi.org/10.21638/spbu10.2025.108

Одной из важных подзадач для оценки и прогнозирования урожайности является картирование культур сельскохозяйственных растений. В последние годы для ее решения активно используются данные дистанционного зондирования, позволяющие оперативно получать информацию о состоянии полей, а также методы искусственного интеллекта. Цель работы — исследование возможностей применения нейросетевых методов для определения культур сельскохозяйственных растений по данным дистанционного зондирования. За основу взяты два различных набора данных: открытый датасет спутниковых снимков PASTIS, а также мозаика аэрофотоснимков Агрофизического научноисследовательского института, полученная на полях Ленинградской обл. с помощью беспилотной системы Геоскан-401. Использовались пять моделей сегментации (U-Net, U-Net 3+, DeepLabV3, FCN, Swin Transformer) для обучения и оценивалась их производительность на наборе данных спутниковых изображений. Результаты эксперимента показали, что точность моделей U-Net 3+ и U-Net значительно выше, чем других моделей. При этом перенос моделей, обученных на спутниковых изображениях с низким разрешением, на аэрофотоснимки с высоким разрешением для дальнейшего обучения позволил эффективно улучшить производительность моделей.

Ключевые слова: картирование культур растений, спутниковые снимки, аэрофотосъемка, нейросетевые модели.

1. Введение. Процесс принятия эффективных управленческих решений в производстве растениеводческой продукции обусловлен множеством сложно предсказуемых факторов, как правило, природного характера. В связи с этим у производителей возникает необходимость регулярного проведения мониторинга состояния сельскохозяйственных посевов, а также прогнозирования урожайности [1]. Особенно актуальны эти задачи для зон рискованного земледелия, где высокий процент возникновения неблагоприятных явлений, таких как засуха или заморозки. Следует отметить, что подобные территории составляют бо́льшую часть от общей площади возделываемых земель.

^{*} Исследование выполнено за счет гранта Российского научного фонда
 \mathbb{N} 24-21-00231, https://rscf.ru/project/24-21-00231/.

[©] Санкт-Петербургский государственный университет, 2025

Благодаря развитию технологий дистанционного зондирования и методов искусственного интеллекта появились новые возможности для оперативного недеструктивного обследования состояния сельскохозяйственной территории [2–5]. Одной из важных подзадач для оценки и прогнозирования урожайности является картирование культур сельскохозяйственных растений [6]. В последние годы активно для этих целей используются спутниковые снимки [7, 8].

В современных исследованиях, связанных с сегментацией изображений в задачах точного земледелия, все более перспективными становятся нейросетевые подходы. Выделяются в этом направлении такие модели как U-Net [9], U-Net 3+ [10], FCN [11], Swin Transformer [12], DeepLabV3+ [13] и др. В последние годы также представляет интерес подход с переносным обучением. Так, используя его для дообучения предварительно обученных моделей [14], достигнута высокая точность в задаче классификации гиперспектральных изображений.

Цель работы — изучение возможностей применения нейросетевых методов для определения культур сельскохозяйственных растений по данным дистанционного зондирования.

2. Объекты и методы. Объектами исследования являются изображения сельскохозяйственных полей. В работе за основу взяты два различных набора данных: открытый датасет спутниковых снимков PASTIS [15], а также мозаика аэрофотоснимков Агрофизического научно-исследовательского института (АФИ) [16].

2.1. Набор данных PASTIS. Он включает 2433 квадратных патча, каждый размером 128 × 128 пикселей, полученных со спутника Sentinel-2, каждый патч содержит 10 спектральных полос (B02, B03, B04, B05, B06, B07, B08, B8A, B11, B12) с разрешением 10 м.

Данные содержат информацию о сельскохозяйственных культурах из разных регионов Франции за период с августа 2018 г. по ноябрь 2019 г., как показано на рис. 1 (изображение взято из документации по использованию PASTIS). Каждый



Рис. 1. Местоположение выборок данных спутниковой съемки открытого датасета PASTIS [15]

патч имеет от 33 до 61 временных образцов. Также представлены различные климатические условия, отражающие реальные условия для сельскохозяйственной идентификации, что значительно помогает в улучшении обобщающей способности модели.

Этот набор данных включает 20 категорий: 18 классов сельскохозяйственных культур, класс фона и пустая метка (табл. 1).

Метка	Класс
0	Background (Фон)
1	Meadow (Луг)
2	Sort winter wheat (Мягкая озимая пшеница)
3	Corn (Кукуруза)
4	Winter barlery (Озимый ячмень)
5	Winter raspesees (Озимый рапс)
6	Spring barley (Яровой ячмень)
7	Sunflower (Подсолнух)
8	Grapevine (Виноград)
9	Beet (Свекла)
10	Winter triticale (Озимый тритикале)
11	Winter durum wheat (Озимая твердая пшеница)
12	Fruits, vegetables, flowers (Фрукты, овощи, цветы)
13	Potatos (Картофель)
14	Leguminous fodder (Бобовые корма)
15	Soybeans (Соевые бобы)
16	Orchard (Фруктовый сад)
17	Mixed cereal (Смешанные злаковые)
18	Sorghum (Copro)
19	Void label (Пустая метка)

Таблица 1. Перечень классов открытого датасета PASTIS

2.2. Набор данных АФИ. Датасет основан на мозаике аэрофотоснимков, полученных в 2017 г. на биополигоне АФИ, расположенном в Ленинградской обл. Съемка осуществлялась с помощью беспилотной авиационной системы Геоскан-401, оснащенной двумя цифровыми камерами Sony, позволяющими собирать изображения в четырех спектральных каналах: красный (Red), зеленый (Green), синий (Blue), ближний инфракрасный (NIR). Пространственное разрешение составляло 1–5 см/пиксель. Исходные снимки предварительно обрабатывались, в результате были построены ортофотопланы, как, например, на рис. 2.

Разметка датасета АФИ выполнялась вручную, были выбраны 7 наиболее представительных категорий — 6 классов сельскохозяйственных культур и класс фона (табл. 2).

Метка	Класс
0	Background (Фон)
1	Spring wheat (Яровая пшеница)
2	Galege officinalis (Козлятник)
3	Forb (Многолетние травы)
4	Barley (Ячмень)
5	Potato (Картофель)
6	Spring barley (Яровой ячмень)
7	Jerusalem (Топинамбур)

Таблица 2. Перечень классов датасета АФИ

2.3. Методы. Исследование состоит из двух частей. Первая направлена на анализ результатов обучения пяти выделенных моделей (U-Net, U-Net 3+, FCN,



Рис. 2. Схема культур растений датасета АФИ 1, 2, 5, 6, 8–12, 14, 16 — сено; 3, 7 — разнотравье; 4 — озимая пшеница; 13 — топинамбур; 15 — овес; 17 — картофель; 18, 22 — пар под озимую пшеницу; 19 — ежа; 20 — яровая пшеница; 21 — тестовый полигон.

Swin Transformer, DeepLabV3+) на наборе данных спутниковых изображений PASTIS и проверку того, обладают ли модели высокой обобщающей способностью, чтобы справляться с задачами сегментации сельскохозяйственных изображений. Вторая часть направлена на перенос обученных моделей на изображения с беспилотника и анализ их производительности.

Экспериментальная схема представлена на рис. 3. В начале эксперимента данные подвергаются предварительной обработке, чтобы изображения соответствовали ожидаемому входу для каждой модели. Количество входных каналов для разных моделей различается. Модели U-Net и U-Net 3+ могут принимать изображения с множеством каналов, в то время как модели DeepLabV3, FCN и Swin Transformer, использующие предварительно обученные модели, принимают только трехканальные изображения.



Рис. 3. Схема обучения моделей

Основными метриками валидации служат параметры Precision, Recall, F1, Overall Accuracy, Mean IoU:

$$Precision = \frac{TP}{TP + FP},$$

где ТР представляет собой истинно положительные результаты (True Positive), а FP — ложно положительные результаты (False Positive); используется для оценки доли истинно положительных результатов среди всех предсказанных положительных результатов;

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}},$$

где FN представляет собой ложно отрицательные результаты (False Negative), т. е. образцы текущей категории, предсказанные как другие категории; применяется для оценки доли истинно положительных результатов среди всех фактически положительных образцов;

 $F1 = 2 \cdot \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$

объединяет точность и полноту, чтобы сбалансировать их влияние; при плохом качестве тренировочных образцов применение только этих двух показателей может привести к неправильной классификации, потому F1-оценка позволяет модели более всесторонне оценивать наличие экстремальных случаев, что лучше отражает производительность модели на несбалансированных данных;

$$Overall Accuracy = \frac{TP + TN}{TP + TN + FP + FN},$$

где TN представляет собой истинно отрицательные результаты; используется для оценки доли правильно предсказанных образцов среди общего числа образцов;

$$IoU = \frac{|A \cap B|}{|A \cup B|},$$

где A представляет собой предсказанную область, а *B* — реальную область. Этот метод оценивает точность предсказания, определяя долю пересечения предсказанных и реальных областей на их объединение, т. е. насколько велика площадь их пересечения;

Mean IoU =
$$\frac{1}{N} \sum_{i=1}^{N} \text{IoU}_i$$
,

где N — количество категорий. Среднее значение IoU для всех категорий более полно оценивает способность модели к предсказанию.

3. Результаты и их обсуждение. Для обучения применялась видеокарта NVIDIA GeForce RTX 3050Ti, версия CUDA — 12.1, версия torch — 2.2.2+cu121. Было выделено 80 % набора данных для обучающего набора, оставшиеся 20 % — для валидационного. При загрузке обучающего набора данные перемешивались случайным образом, чтобы предотвратить зависимость модели от них и избегание локальных минимумов. Обучающий и валидационный наборы данных были закреплены в памяти (Pinned Memory), что позволило CUDA напрямую обращаться к этой области памяти, избегая задержек при передаче данных из-за механизма страничной памяти и ускоряя передачу данных из памяти CPU в память GPU. Для предотвращения переобучения и потерь вычислительной мощности использовался механизм ранней остановки (Early Stopping). В качестве функции потерь была выбрана перекрестная энтропия (Crossentropy).

В этом исследовании использовались пять моделей сегментации (U-Net, U-Net 3+, DeepLabV3, FCN, Swin Transformer) для обучения и оценивалась их производительность на наборе данных спутниковых изображений. Результаты по метрикам валидации представлены в табл. 3.

Молель	Параметр, %				
модель	Precision	Recall	F1	OA	MIoU
U-Net	88.86	75.60	81.69	82.20	62.60
U-Net 3+	90.14	80.91	85.27	84.42	64.15
FCN	82.61	75.01	78.63	82.44	61.17
DeeplabV3	82.75	74.55	78.32	79.69	60.52
Swin Tranformer	72.86	68.01	70.35	74.49	54.14

Таблица 3. Результаты по метрикам валидации моделей для датасета PASTIS

Результаты эксперимента показывают, что точность моделей U-Net 3+ и U-Net значительно превосходит точность других моделей. Это означает, что данные модели способны точнее идентифицировать области с сельскохозяйственными культурами и одновременно уменьшить количество ложных срабатываний на фон. Производительность моделей DeepLabV3 и FCN примерно одинаковая, но немного ниже, чем у первых двух моделей, в то время как точность модели Swin Transformer значительно хуже, она отстает от лучшей модели U-Net 3+ на 17~%, что свидетельствует о значительном различии в способности двух моделей различать сельскохозяйственные культуры и фон. Это может быть вызвано разными способами ввода данных в модель. В отличие от моделей FCN и DeepLabV3, которые изменяют входной слой для обработки 10 каналов, Swin Transformer использует только соответствующие RGB три канала для обучения, что приводит к потере информации из 7 каналов на этапе ввода, снижая производительность модели по сравнению с другими моделями. Схожие результаты также демонстрирует рис. 4.



Ground trithing



Label



Puc. 4. Результаты картирования классов

Молель	Параметр, %				
модель	Precision	Recall	F1	OA	MIoU
U-Net	89.44	86.98	88.15	95.25	83.81
U-Net 3+	93.77	92.84	93.29	97.18	85.64
FCN	92.35	91.93	92.13	96.67	84.78
DeepLabV3	92.46	91.73	92.08	96.75	84.66
Swin Tranformer	93.71	91.62	92.45	97.03	85.17

Таблица 4. Результаты по метрикам валидации моделей для датасета АФИ

Путем переноса модели на набор данных АФИ для дальнейшего обучения в этом эксперименте были получены результаты, представленные в табл. 4. Из их анализа видно, что модель U-Net 3+ по-прежнему является лучшей по многим проверочным показателям. Остальные модели показывают схожие результаты, но в отличие от предыдущего переноса модель Swin Transformer демонстрирует очень хорошие результаты по всем показателям. Она не только не является худшей по всем показателям (как в табл. 3), но и по общей оценке уступает лишь модели U-Net 3+. Повышение производительности модели Swin Transformer связано с тем, что изображения с дрона в отличие от спутниковых изображений имеют только 4 канала. Помимо RGB трехцветного, они имеют только один дополнительный канал NIR. Поэтому, когда модели U-Net и U-Net 3+ принимают 4 канала, модель Swin Transformer принимает только на один канал меньше, что не приводит к значительной потере характеристик. Кроме того, высокое разрешение аэрофотоснимков и более детализированные особенности обеспечивают модели Swin Transformer более богатые тренировочные данные, что позволяет ей лучше извлекать характеристики и уточнять границы, связанные с категориями образцов.

В табл. 5 представлено общее сравнение полученных результатов.

Параметр	U-Net (PASTIS)	U-Net (АФИ)	Swin Transformer	Swin Transformer
		. ,	(PASTIS)	(АФИ)
Precision	88.86	89.44	72.86	93.71
Recall	75.60	86.98	68.01	91.62
F1	81.69	88.15	70.35	9.45
OA	82.20	95.25	74.49	97.03
MIoU	62.60	83.81	50.14	85.17

Таблица 5. Сравнение полученных результатов (%)

По результатам двух экспериментов с обучением легко заметить, что модели могут улучшить свою производительность, если использовать подходящий набор данных для переноса обучения. Например, модели U-Net и Swin Transformer после извлечения признаков на спутниковых изображениях значительно улучшают свои показатели при извлечении признаков на аэфротоснимках.

4. Заключение. В данной работе проанализирована производительность пяти различных моделей сегментации (U-Net, U-Net 3+, DeepLabV3, FCN, Swin Transformer) в задаче определения сельскохозяйственных культур на спутниковых снимках, а затем с использованием переноса обучения модели были применены на аэрофотоснимках. Модель U-Net 3+ в ходе исследования продемонстрировала лучшие результаты картирования культур среди пяти рассмотренных по всем валидационным показателям при обучении на изображениях как с низким разрешением, так и с высоким. Модель Swin Transformer из-за ограничения числа каналов на входном слое имеет менее широкий диапазон применения, показывая худшие результаты на спутниковых изображениях с мультиспектральными каналами и хорошие результаты только на аэрофотоснимках с меньшим количеством каналов. При этом перенос моделей, обученных на изображениях с низким разрешением, на изображения с высоким разрешением для дальнейшего обучения позволяет эффективно улучшить производительность моделей.

Литература

1. Kwak G. H., Park N. W. Impact of texture information on crop classification with machine learning and UAV images // Applied Sciences. 2019. Vol. 9. Art. N 643. https://doi.org/10.3390/app9040643

2. Bure V. M., Mitrofanova O. A., Mitrofanov E. P., Petrushin A. F. Remote sensing data processing for plant production control // Stability and Control Processes. Proceedings of the 4th International Conference dedicated to the memory of professor Vladimir Zubov. Cham: Springer, 2022. P. 753–758. https://doi.org/10.1007/978-3-030-87966-2_86

3. Weiss M., Jacob F., Duveiller G. Remote sensing for agricultural applications: A meta-review // Remote Sensing of Environment. 2020. Vol. 236. Art. N 111402. https://doi.org/10.1016/j.rse.2019.111402

4. Митрофанова О. А., Митрофанов Е. П., Буре Н. А. Применение онтологического подхода к проектированию геопространственной базы опытных данных для информационного обеспечения исследований в точном земледелии // Вестник Санкт-Петербургского университета. Прикладная математика. Информатика. Процессы управления. 2022. Т. 18. Вып. 2. С. 253–262. https://doi.org/10.21638/11701/spbu10.2022.206

5. Молин А. Е., Блеканов И. С., Митрофанов Е. П., Митрофанова О. А. Методы генерации синтетических данных для обучения нейросетей в задаче сегментации уровня азотного режима растений на снимках беспилотных летательных аппаратов на сельскохозяйственном поле // Вестник Санкт-Петербургского университета. Прикладная математика. Информатика. Процессы управления. 2024. Т. 20. Вып. 1. С. 20–33. https://doi.org/10.21638/11701/spbu10.2024.103

6. Kim Y., Park N.-W., Lee K.-D. Self-learning based land-cover classification using sequential class patterns from past land-cover maps // Remote Sensing. 2017. Vol. 9. Art. N 921. https://doi.org/10.3390/rs9090921

7. Selea T., Pslaru M.-F. AgriSen — a dataset for crop classification // 22nd International Symposium on Symbolic and Numeric Algorithms for Scientific Computing (SYNASC). Timisoara, Romania, 2020. P. 259–263. https://doi.org/10.1109/SYNASC51798.2020.00049

8. Zhou Y., Zhu W., Feng L., Gao J., Chen Y., Zhang X., Luo J. Hierarchical classification for improving parcel-scale crop mapping using time-series Sentinel-1 data // Journal of Environmental Management. 2024. Vol. 369. Art. N 122251. https://doi.org/10.1016/j.jenvman.2024.122251

9. Iglovikov V., Shvets A. TernausNet: U-Net with VGG11 encoder pre-trained on ImageNet for image segmentation // arXiv: 1801.05746. 2018. https://doi.org/10.48550/arXiv.1801.05746

10. Huang H., Lin L., Tong R., Hu H., Zhang Q., Iwamoto Y., Han X., Chen Y.-W., Wu J. UNet 3+: A full-scale connected UNet for medical image segmentation // arXiv: 2004.08790. 2020. https://doi.org/10.48550/arXiv.2004.08790

11. Fu G., Liu C., Zhou R., Sun T., Zhang Q. Classification for high resolution remote sensing imagery using a fully convolutional network // Remote Sensing. 2017. Vol. 9. Art. N 498. https://doi.org/10.3390/rs9050498

12. Xu X., Zou J., Cai J., Zou D. Multi-scale contextual swin transformer for crop image segmentation // Journal of Physics: Conference Series. 2024. Vol. 2759. Art. N 012012. https://doi.org/10.1088/1742-6596/2759/1/012012

13. Lu J., Zhou B., Wang B., Zhao Q. Land cover classification of remote sensing images based on improved DeepLabV3+ network // Journal of Physics: Conference Series. 2022. Vol. 2400. Art. N 012035. https://doi.org/10.1088/1742-6596/2400/1/012035

14. He X., Chen Y., Ghamisi P. Heterogeneous transfer learning for hyperspectral image classification based on convolutional neural network // IEEE Transactions on Geoscience and Remote Sensing. 2020. Vol. 58. N 5. P. 3246–3263. https://doi.org/10.1109/TGRS.2019.2951445

15. Garnot V. S. F., Landrieu L. Panoptic segmentation of satellite image time series with convolutional temporal attention networks // Proceedings of the IEEE International Conference on Computer Vision. Montreal, Canada: Institute of Electrical and Electronics Engineers Inc., 2021. P. 4852–4861. https://doi.org/10.1109/ICCV48922.2021.00483

16. Буре В. М., Митрофанов Е. П., Митрофанова О. А., Петрушин А. Ф. Выделение однородных зон сельскохозяйственного поля для закладки опытов с помощью беспилотного летательного

Вестник СПбГУ. Прикладная математика. Информатика... 2025. Т. 21. Вып. 1

аппарата // Вестник Санкт-Петербургского университета. Прикладная математика. Информатика. Процессы управления. 2018. Т. 14. Вып. 2. С. 145–150. https://doi.org/10.21638/11701/spbu10.2018.206

Статья поступила в редакцию 26 октября 2024 г. Статья принята к печати 9 декабря 2024 г.

Контактная информация:

Muтрофанова Ольга Александровна — канд. техн.
наук; https://orcid.org/0000-0002-7059-4727, o.a.mitrofanova@spbu.ru

Нин Ся — магистр; n282438802@gmail.com

Митрофанов Евгений Павлович — канд. техн.
наук; https://orcid.org/0000-0002-1967-5126, e.mitrofanov@spbu.ru

Determination of crop types based on remote sensing data using artificial intelligence methods^{*}

O. A. Mitrofanova¹, S. Nin¹, E. P. Mitrofanov^{1,2}

¹ St. Petersburg State University, 7–9, Universitetskaya nab., St. Petersburg, 199034, Russian Federation

 2 Agrophysical Research Institute, 14, Grazhdansky pr., St. Petersburg, 195220, Russian Federation

For citation: Mitrofanova O. A., Nin S., Mitrofanov E. P. Determination of crop types based on remote sensing data using artificial intelligence methods. *Vestnik of Saint Petersburg University.* Applied Mathematics. Computer Science. Control Processes, 2025, vol. 21, iss. 1, pp. 112–121. https://doi.org/10.21638/spbu10.2025.108 (In Russian)

One of the important subtasks for estimating and forecasting yields is crop mapping. In recent years, remote sensing data has been actively used to solve it, which allows us to quickly obtain information about the state of fields, as well as artificial intelligence methods. The purpose of this work was to investigate the possibilities of using neural network methods to determine crops of agricultural plants based on remote sensing data. Two different data sets are taken as a basis: an open dataset of PASTIS satellite images, as well as a mosaic of aerial photographs of the Agrophysical Research Institute obtained in the fields of the Leningrad region using the Geoscan-401 unmanned system. Five segmentation models (U-Net, U-Net 3+, DeepLabV3, FCN, Swin Transformer) were used for training and their performance was evaluated on a set of satellite image data. The results of the experiment showed that the accuracy of the U-Net 3+ and U-Net models significantly exceeds other models. At the same time, the transfer of models trained on low-resolution satellite images to high-resolution aerial photographs for further training has effectively improved the performance of models.

Keywords: crop mapping, satellite imagery, aerial photography, neural network models.

References

1. Kwak G. H., Park N. W. Impact of texture information on crop classification with machine learning and UAV images. *Applied Sciences*, 2019, vol. 9, art. no. 643. https://doi.org/10.3390/app9040643

2. Bure V. M., Mitrofanova O. A., Mitrofanov E. P., Petrushin A. F. Remote sensing data processing for plant production control. Stability and Control Processes. Proceedings of the 4th International Conference dedicated to the memory of professor Vladimir Zubov. Cham, Springer, 2022, pp. 753–758. https://doi.org/10.1007/978-3-030-87966-2_86

3. Weiss M., Jacob F., Duveiller G. Remote sensing for agricultural applications: A meta-review. Remote Sensing of Environment, 2020, vol. 236, art. no. 111402. https://doi.org/10.1016/j.rse.2019.111402

^{*} This research was supported by the Russian Science Foundation, project N 24-21-00231, https://rscf.ru/project/24-21-00231/.

4. Mitrofanova O. A., Mitrofanov E. P., Bure N. A. Primenenie ontologicheskogo podkhoda k proektirovaniiu geoprostranstvennoi bazy opytnykh dannykh dlia informatsionnogo obespecheniia issledovanii v tochnom zemledelii [Ontological approach application to the design of a geospatial experimental database for information support of research in precision agriculture]. Vestnik of Saint Petersburg University. Applied Mathematics. Computer Science. Control Processes, 2022, vol. 18, iss. 2, pp. 253–262. https://doi.org/10.21638/11701/spbu10.2022.206 (In Russian)

5. Molin A. E., Blekanov I. S., Mitrofanov E. P., Mitrofanova O. A. Metody generatsii sinteticheskikh dannykh dlia obucheniia neirosetei v zadache segmentatsii urovnia azotnogo rezhima rastenii na snimkakh bespilotnykh letatel'nykh apparatov na sel'skokhoziaistvennom pole [Synthetic data generation methods for training neural networks in the task of segmenting the level of crop nitrogen status on UAV images of agricultural fields]. Vestnik of Saint Petersburg University. Applied Mathematics. Computer Science. Control Processes, 2024, vol. 20, iss. 1, pp. 20–33. https://doi.org/10.21638/11701/spbu10.2024.103 (In Russian)

6. Kim Y., Park N.-W., Lee K.-D. Self-learning based land-cover classification using sequential class patterns from past land-cover maps. *Remote Sensing*, 2017, vol. 9, art. no. 921. https://doi.org/10.3390/rs9090921

7. Selea T., Pslaru M.-F. AgriSen — a dataset for crop classification. 22nd International Symposium on Symbolic and Numeric Algorithms for Scientific Computing (SYNASC). Timisoara, Romania, 2020, pp. 259–263. https://doi.org/10.1109/SYNASC51798.2020.00049

8. Zhou Y., Zhu W., Feng L., Gao J., Chen Y., Zhang X., Luo J. Hierarchical classification for improving parcel-scale crop mapping using time-series Sentinel-1 data. *Journal of Environmental Management*, 2024, vol. 369, art. no. 122251. https://doi.org/10.1016/j.jenvman.2024.122251

9. Iglovikov V., Shvets A. TernausNet: U-Net with VGG11 encoder pre-trained on ImageNet for image segmentation. arXiv: 1801.05746, 2018. https://doi.org/10.48550/arXiv.1801.05746

10. Huang H., Lin L., Tong R., Hu H., Zhang Q., Iwamoto Y., Han X., Chen Y.-W., Wu J. UNet 3+: A full-scale connected UNet for medical image segmentation. arXiv: 2004.08790, 2020. https://doi.org/10.48550/arXiv.2004.08790

11. Fu G., Liu C., Zhou R., Sun T., Zhang Q. Classification for high resolution remote sensing imagery using a fully convolutional network. *Remote Sensing*, 2017, vol. 9, art. no. 498. https://doi.org/10.3390/rs9050498

12. Xu X., Zou J., Cai J., Zou D. Multi-scale contextual swin transformer for crop image segmentation. *Journal of Physics: Conference Series*, 2024, vol. 2759, art. no. 012012. https://doi.org/10.1088/1742-6596/2759/1/012012

13. Lu J., Zhou B., Wang B., Zhao Q. Land cover classification of remote sensing images based on improved DeepLabV3+ network. *Journal of Physics: Conference Series*, 2022, vol. 2400, art. no. 012035. https://doi.org/10.1088/1742-6596/2400/1/012035

14. He X., Chen Y., Ghamisi P. Heterogeneous transfer learning for hyperspectral image classification based on convolutional neural network. *IEEE Transactions on Geoscience and Remote Sensing*, 2020, vol. 58, no. 5, pp. 3246–3263. https://doi.org/10.1109/TGRS.2019.2951445

15. Garnot V. S. F., Landrieu L. Panoptic segmentation of satellite image time series with convolutional temporal attention networks. *Proceedings of the IEEE International Conference on Computer Vision*. Montreal, Canada, Institute of Electrical and Electronics Engineers Inc. Publ., 2021, pp. 4852–4861. https://doi.org/10.1109/ICCV48922.2021.00483

16. Bure V. M., Mitrofanov E. P., Mitrofanova O. A., Petrushin A. F. Vydelenie odnorodnykh zon sel'skokhoziaistvennogo polia dlia zakladki opytov s pomoshch'iu bespilotnogo letatel'nogo apparata [Selection of homogeneous zones of agricultural field for laying of experiments using unmanned aerial vehicle]. Vestnik of Saint Petersburg University. Applied Mathematics. Computer Science. Control Processes, 2018, vol. 14, iss. 2, pp. 145–150. https://doi.org/10.21638/11701/spbu10.2018.206 (In Russian)

Received: October 26, 2024. Accepted: December 9, 2024.

Authors' information:

 $Olga\ A.\ Mitrofanova$ — PhD in Technics; https://orcid.org/0000-0002-7059-4727, o.a.
mitrofanova@spbu.ru

Sya Nin — Master; n282438802@gmail.com

 $Evgenii\ P.\ Mitrofanov$ — PhD in Technics; https://orcid.org/0000-0002-1967-5126, e.mitrofanov@spbu.ru