

Модификация алгоритма разделения смежных объектов в задаче сегментации изображений сельхозугодий на данных дистанционного зондирования земной поверхности

Р. В. Ларионов, В. В. Хрящев, А. Л. Приоров

Ярославский государственный университет им. П. Г. Демидова

Ярославль, 150003, Россия

E-mail: v.khryashchev@uniyar.ac.ru

Рассматривается задача автоматической сегментации сельскохозяйственных угодий на спутниковых изображениях дистанционного зондирования Земли. Основной фокус исследования направлен на решение проблемы разделения смежных объектов, имеющих сходные спектральные характеристики, что становится частой причиной слияния нескольких физически различных полей в единый полигон при использовании стандартных нейросетевых подходов. Проанализированы современные методы выделения границ полей, включая нейросетевые архитектуры на основе U-Net. Для повышения качества сегментации предложена модифицированная методика обучения, включающая адаптивную балансировку обучающих пакетов для устранения дисбаланса данных, введение дополнительного класса «узкая область между объектами», использование карты весов для границ в функции потерь, а также метод инвариантности к аугментации. Эксперименты на наборе изображений в видимом и ближнем инфракрасном диапазонах со спутника Sentinel-2 для территории европейской части России показали, что совокупность предложенных модификаций позволяет повысить точность сегментации с 0,68 до 0,78 по метрике Dice и с 0,39 до 0,51 по метрике детектирования F1 по сравнению с базовой архитектурой U-Net. Это подтверждает способность предложенного алгоритма корректно разделять сельскохозяйственные угодья на отдельные объекты.

Ключевые слова: дистанционное зондирование Земли, сегментация изображений, распознавание сельхозугодий, глубокое обучение, свёрточная нейронная сеть

Одобрена к печати: 17.04.2026

DOI: 10.21046/2070-7401-2026-23-4-51-62

Введение

В современном мире оперативное и достоверное получение информации о состоянии земной поверхности становится критически важным фактором для рационального природопользования, устойчивого развития аграрного сектора и обеспечения продовольственной безопасности. Данные дистанционного зондирования Земли (ДЗЗ) из космоса играют в этом процессе ключевую роль, предоставляя уникальную возможность регулярного мониторинга огромных территорий с высоким временным и пространственным разрешением. Спутниковые снимки позволяют отслеживать динамику сельскохозяйственных культур, оценивать ущерб от стихийных бедствий, прогнозировать урожайность и контролировать соблюдение севооборотов, что делает их незаменимым инструментом для агропромышленного комплекса и государственных органов управления (Федоринов и др., 2023).

Однако эффективное использование спутниковых данных невозможно без их предварительной структуризации и интерпретации. Ключевой и нетривиальной задачей в этой области является автоматическое распознавание и выделение границ сельскохозяйственных полей, т.е. решение задачи сегментации изображений (Денисов и др., 2024). В отличие от природных ландшафтов, агроландшафты представляют собой сложную мозаику антропогенных объектов, где границы полей могут быть как чёткими (разделённые дорогами или лесополосами), так и размытыми, особенно в регионах с мелкоконтурным землепользованием или в системах орошаемого земледелия, где границы определяются перепадами увлажнения (Амирова и др., 2020).

Актуальность задачи сегментации полей обусловлена широким спектром её практических приложений. Во-первых, картографирование границ служит основой для систем точного земледелия, позволяя оптимизировать внесение удобрений и средств защиты растений (Трошко и др., 2025a). Во-вторых, это критически важный этап для верификации субсидирования в сельском хозяйстве и выявления нецелевого использования земель (Федоринов и др., 2024). Выделенные контуры полей становятся базисом для дальнейшего анализа севооборотов и временной динамики вегетационных индексов. Таким образом, разработка надёжных методов и алгоритмов сегментации сельскохозяйственных угодий по спутниковым изображениям представляет собой важную научную и прикладную проблему, решение которой способствует повышению эффективности всего агропромышленного комплекса (Трошко и др., 2025b).

Несмотря на огромный прогресс, достигнутый в задаче сегментации сельхозугодий на изображениях ДЗЗ с использованием методов глубокого машинного обучения за последние 10 лет, существует ряд проблем, которые исследователям необходимо разрешить. В данном исследовании фокус сделан на актуальной задаче разделения смежных объектов. Стандартные алгоритмы сегментации изображений классифицируют каждый пиксель изображения, присваивая ему метку класса при бинаризации по порогу. Когда два или более отдельных сельскохозяйственных поля соприкасаются друг с другом и имеют схожие спектральные характеристики, нейросетевая модель выводит для них единую, сплошную маску класса «поле». В результате несколько физически разных полей сливаются в один большой полигон.

Среди причин такого поведения нейросетевой модели можно выделить:

- Спектральная неотличимость. Если соседние поля засеяны одной и той же культурой или спектрально близкими культурами (например, ячмень и пшеница) и находятся на одинаковой степени вегетации, то их спектральные сигнатуры практически неразличимы (Kamilaris, Prenafeta-Boldú, 2018).
- Отсутствие явной границы между полями. При низком разрешении спутникового изображения такие разделители, как дорога, канава, река, могут иметь ширину в единицы пикселей, что создаёт иллюзию сплошного объекта (Kamilaris et al., 2017).
- Фокус обучения на семантике. Стандартные способы обучения нейронных сетей при сегментации оптимизированы для максимизации попиксельной точности, в то время как точность разделения объектов на отдельные полигоны часто игнорируется (Kamilaris et al., 2017).

Разрешению описанных выше проблем и посвящено данное исследование. Сегментация сельскохозяйственных полей с помощью нейросетевых алгоритмов глубокого обучения — это одно из перспективных и в то же время сложных направлений в применении методов искусственного интеллекта для сельского хозяйства (Скворцов и др., 2018). Для решения данной задачи исследователи предлагают разные подходы. В качестве базовой нейросетевой архитектуры взята сеть U-Net (Ronneberger et al., 2015; Waldner, Diakogiannis, 2020; Xu et al., 2024), хорошо зарекомендовавшая себя в задачах сегментации изображений ДЗЗ.

Обзор литературы по теме исследования

В работе (Waldner, Diakogiannis, 2020) авторы предлагают архитектуру на основе сетей U-Net (Ronneberger et al., 2015) и ResNet для автоматического выделения границ полей на основе изображений со спутника Sentinel-2. Ключевая особенность подхода заключается в использовании многозадачного обучения: алгоритм одновременно предсказывает маску самого поля, его границы и карту расстояний до ближайшей границы. Это позволяет справиться с важной проблемой — разделением смежных полей с похожими спектральными характеристиками.

В другой работе исследователи сфокусировались на проблеме точной локализации краёв полей на изображениях высокого разрешения (Xu et al., 2024). Авторы модифицируют клас-

сическую нейросетевую архитектуру U-Net, внедряя механизм «внимания» и специальную функцию потерь, ориентированную на границы (*англ.* boundary-aware loss). Стандартные методы сегментации часто размывают края объектов, что критично для изображений сельхозугодий. Предложенный метод усиливает веса пикселей, находящихся на стыке полей, заставляя нейронную сеть повышать «штрафы» за ошибки в этих зонах. Результаты показывают, что такой подход позволяет получать геометрически более правильные полигоны полей, требующие меньше дополнительной пост-обработки по сравнению с базовыми нейросетевыми моделями.

В работе российских учёных (Толпин и др., 2019) рассматривается задача сегментации с учётом специфики отечественного земледелия (большие площади, разнородность культур). Главная идея статьи заключается в использовании не одиночных изображений, а временных рядов, составленных из вегетационных индексов NDVI (*англ.* Normalized Difference Vegetation Index) за весь сезон. Применение временной составляющей значительно повышает точность классификации границ полей в условиях облачности и сезонной изменчивости, характерных для средней полосы России.

Несмотря на доминирование методов глубокого обучения в задаче обнаружения полей, в настоящее время также существуют исследования, посвящённые использованию классических методов сегментации. В частности, работа (Belgiu, Csillik, 2018) представляет собой пример современного применения классического метода OBIA (*англ.* Object-Based Image Analysis). В рамках этого подхода изображение сначала сегментируется на примитивы с помощью алгоритма многомасштабной пирамиды. Затем к полученным объектам применяются классические алгоритмы машинного обучения для бинарной классификации «поле/не поле». Полученные результаты показывают, что в условиях простой геометрии полей и ограниченного объёма обучающих данных классический подход OBIA всё ещё может конкурировать с нейросетевыми алгоритмами, будучи при этом более интерпретируемым и менее требовательным к вычислительным ресурсам.

Описание набора данных

Для проведения исследования собрана база изображений со спутника Sentinel-2 прибором MSI (*англ.* Multispectral Instrument) с пространственным разрешением 10 м/пиксель. Использованы только каналы B2, B3, B4 и B8 (синий, зелёный, красный и ближний инфракрасный). Съёмка велась для европейской части России в 2020–2022 гг. с учётом зонального и сезонного разнообразия. Спутниковые изображения имели следующие основные характеристики: уровень обработки 2A; облачность не более 70 % покрытия снимка; доля значимых пикселей более 50 %; проведена орторектификация; точечные размеры каждого канала попарно идентичны; точечные размеры каналов не менее 1024 точек в каждом измерении; информационная составляющая каждой точки канала равнялась 16 бит.

Каждое изображение размечено экспертами на один класс «сельхозугодья» с использованием геоинформационной системы с открытым исходным кодом QGIS (*англ.* Quantum Geographic Information Systems) (<https://qgis.org>). Для обучения и тестирования нейросетевых моделей проведено разбиение снимков на квадратные области размером 512×512 пикселей с шагом 256 пикселей. Итоговая статистика полученного набора представлена в *табл. 1*. Примеры размеченных изображений приведены на *рис. 1*.

Таблица 1. Статистика собранного набора изображений

Количество изображений 512×512	Обучающая выборка	Тестовая выборка
Всего	91 765	756
• с сельхозугодьями	9 979	723
• без сельхозугодий	81 786	33




Рис. 1. Пример размеченного изображения и соответствующей бинарной маски: *а* — изображение в формате RGB (англ. Red, Green, Blue); *б* — эталонная маска с выделенным классом

Настройка параметров обучения нейронной сети

Разработка алгоритма на основе методов глубокого обучения заключается не только в выборе подходящей архитектуры нейронной сети, но и в тонкой настройке гиперпараметров обучения, которые можно разделить на следующие составляющие: предобработка входных данных, аугментация (искусственное расширение обучающей выборки), формирование обучающих пакетов, функция потерь, алгоритм оптимизации. Изменение каждого из параметров может значительно влиять на итоговое качество обученного алгоритма (Николенко и др., 2019). На рис. 2 изображены этапы предлагаемой методики исследования параметров.



Рис. 2. Этапы исследования процесса обучения нейронной сети

Балансировка данных

Из данных, приведённых в табл. 1, следует, что в собранном наборе данных наблюдается дисбаланс в распределении классов: изображений с сельхозполями значительно меньше, чем фоновых изображений. Данная особенность может негативно отразиться на результатах обу-

чения алгоритма сегментации: при дисбалансе данных модель быстро понимает, что может достичь высокой точности, просто предсказывая все пиксели как доминирующий класс. Такая нейросетевая модель плохо обобщается на новые, ранее не исследованные изображения. Любое небольшое отклонение в форме, яркости или текстуре объекта на новом изображении приводит к ошибкам (Kornblith et al., 2019). В исследовании рассмотрены три политики формирования пакета данных на каждой итерации обучения:

- Случайное формирование обучающего пакета изображений.
- Сбалансированное формирование: половина изображений содержали класс сельхоз-полей, половина — только фон.
- Адаптивная балансировка на основании покласового распределения пикселей в обучающем наборе и средневзвешенного выхода сети на предыдущей итерации обучения (Ларионов и др., 2024). На первых итерациях нейросетевая модель начинает обучаться как обычно с равномерным распределением для вероятности попадания изображения в обучающий пакет. Цель данного этапа — формирование базовых значений весов нейронной сети, способной обнаруживать объекты, пусть и с большой погрешностью. Далее для формирования следующих пакетов начинает учитываться уверенность распознавания алгоритма на определённых примерах. Вероятность попадания изображения с классом k может быть выражена как:

$$P_k = \sigma\left((1 - \text{weight}_k \cdot \text{conf}_k)^\gamma\right), \quad \text{conf}_i = \alpha \cdot \text{conf}_{i-1} + (1 - \alpha)\text{conf}_i,$$

где weight_k — вес класса k в наборе; conf_i — средневзвешенное значение выхода нейронной сети на i -й итерации; σ — функция нормировки на минимальное и максимальное значение; α и γ — сглаживающие коэффициенты.

Методика размножения данных

Специфика спутниковых изображений заключается в том, что они не привязаны к определённым углам поворота, а также могут подвергаться достаточно серьёзным фотометрическим искажениям из-за угла наклона камеры. Поэтому стандартные методы аугментации могут иметь низкую эффективность в задачах сегментации спутниковых изображений. Подход повышения инвариантности к аугментации заключается в том, что исходное изображение изменяется двумя разными способами, и предсказания алгоритма по обоим используемым подходам должны совпадать (Tavera et al., 2022). В первый тип аугментации отнесены случайные изменения масштаба в пределах $[0,9; 1,1]$, случайная обрезка, зеркальные отражения и повороты на углы до 25° . Во второй тип аугментации отнесены случайные повороты на кратные 90° углы и случайные изменения яркости в пределах 10 %. Для обучения на основе такого подхода использовалась общая функция потерь, которая учитывала ошибку сегментации исходного изображения, ошибку сегментации преобразованного изображения и разницу между предсказанием по исходному и преобразованному изображениям. В результате общая функция потерь выражается следующим образом:

$$L_{\text{общ}} = L_{\text{сег}}(x, y) + L_{\text{сег}}(A(x), A(y)) + \lambda L_{\text{ИА}}(x, A(x)), \quad L_{\text{ИА}}(x, A(x)) = \frac{1}{I} \sum_{i \in I} f_i(x) - A^{-1}(f_i(A(x)))^2,$$

где $L_{\text{сег}}$ — ошибка сегментации; $L_{\text{ИА}}$ — разница между предсказаниями по изображению с аугментацией и без неё, выраженная как среднеквадратичная ошибка; A — оператор применения аугментаций; A^{-1} — оператор возврата геометрических аугментаций к изначальной ориентации изображения; I — нормировочный коэффициент, равный размеру изображения; x — исходное изображение; y — экспертная разметка; f_i — предсказание модели. Использование оператора A^{-1} необходимо для корректного расчёта функции потерь по двум различным изображениям. Схематично данный подход изображён на рис. 3.




Рис. 3. Алгоритм обучения нейронной сети с использованием метода инвариантности к аугментации

Предобработка входных данных

Для улучшения разделимости близко расположенных полей в эталонные маски добавлен класс «узкая область между объектами». Он использовался, если расстояние между объектами не превышало трёх пикселей, или 30 м в пространственном разрешении. Дополнительный класс сформирован автоматически с использованием морфологических операций дилатации и эрозии, а также алгоритма водораздела (Gonzalez, Woods, 2017). Пример полученных масок представлен на рис. 4.




Рис. 4. Примеры изображений: *a* — исходное изображение; *б* — маска сельхозугодий; *в* — маска узких областей между сельхозугодьями

Модификация функции потерь

В качестве ещё одного возможного улучшения процесса обучения нейронной сети для разделения близко расположенных полей и формирования более чётких и гладких контуров предлагается добавить увеличенный вес для границ следующим образом (Sedov et al., 2019):

$$w(x) = w_c(x) + w_0 \exp\left(-\frac{(d_1(x) + d_2(x))^2}{2\sigma^2}\right),$$

где $w_c : \Omega \rightarrow \mathbb{R}$ — карта весов, учитывающая частоту появления класса объекта на изображении; $d_1 : \Omega \rightarrow \mathbb{R}$ — расстояние до границы ближайшего объекта; $d_2 : \Omega \rightarrow \mathbb{R}$ — расстояние до границы второго по удалённости объекта; σ — стандартное отклонение, характеризующее степень угасания веса. В данном случае w_0 и σ взяты равными 10 и 5 соответственно. Таким образом, функция потерь принимает следующий вид:

$$Loss_weighted = BCE \cdot w(x) + dice_loss,$$

где BCE (англ. Binary Cross-Entropy) — бинарная кросс-энтропия; $dice_loss$ — функция потерь, выраженная как единица минус коэффициент Сёренсена.

Данный подход позволяет увеличить значение функции потерь для пограничных пикселей и сфокусироваться на извлечении необходимых признаков на редких, но важных пикселях. При этом ключевым моментом становится умножение не всей функции потерь, а только составной части из кросс-энтропии. Визуализация карты весов представлена на рис. 5. На нём демонстрируется, что именно пограничным пикселям объектов был назначен наибольший вес.




Рис. 5. Визуализация карты весов: *а* — оригинальный фрагмент изображения; *б* — эталонная разметка; *в* — маска весов для границ

Результаты моделирования

Для оценки нейросетевых моделей использовался ряд стандартных метрик: коэффициент подобия Сёренсена Dice, метрика отношения пересечения к объединению IoU (англ. Intersection over Union) и адаптированные для задачи сегментации стандартные метрики детектирования на уровне объектов: точность P (англ. Precision), полнота R (англ. Recall) и F -мера 1-го рода F1. Все эти показатели принимают значения из интервала $[0, 1]$ и рассчитываются следующим образом:

$$dice = 2 \frac{|X \cap Y|}{|X| + |Y|}, \quad IoU = \frac{S_{int}}{S_{union}}, \quad P = \frac{TP}{TP + FN}, \quad R = \frac{TP}{TP + FP}, \quad F1 = 2 \frac{PR}{P + R},$$

где X — множество пикселей эталонной маски; Y — множество пикселей, предсказанных алгоритмом; $|X \cap Y|$ — количество элементов, присутствующих в обоих множествах; S_{int} и S_{union} — площади пересечения и объединения между экспертной разметкой и обнаружением, предсказанным алгоритмом; TP (англ. True Positive) — количество правильно определённых объектов; FN (англ. False Negative) — количество пропущенных объектов; FP (англ. False Positive) — количество ложных срабатываний на уровне объектов. Распознанный объект трактуется как истинно-положительный, если предсказание алгоритма пересекается с объектом из эталонной маски более чем на 0,5 по метрике IoU.

Первым этапом численных экспериментов представляется исследование влияния балансировки обучающих пакетов на базе стандартной архитектуры свёрточной нейронной сети U-Net. Результаты тестирования представлены в табл. 2.

Видно, что использование адаптивной балансировки повышает точность на 0,05 по метрике Dice и на 0,04 по метрике F1. Это связано с тем, что при данном подходе обу-

чение происходит не на всех данных из обучающего набора, а только на сложных примерах. Рисунок 6 также иллюстрирует, что при адаптивной балансировке процесс обучения стабильнее, что выражается в меньшем количестве скачков функции потерь на валидационном наборе.

Таблица 2. Результаты для различных политик формирования обучающего пакета

Алгоритм формирования пакета	Dice	F1
Случайный	0,68	0,39
Сбалансированный	0,72	0,41
Адаптивный	0,73	0,43




Рис. 6. Изменение функции потерь на валидационном наборе в зависимости от политики формирования обучающего пакета

Последующее усовершенствование алгоритма сегментации касалось улучшения способности нейронной сети разделять близко расположенные объекты с помощью адаптации входных данных и использованием дополнительного класса узкая область между объектами в эталонных масках, добавления маски весов для границ сельхозполей в функцию потерь и метода инвариантности аугментации. Результаты тестирования отображены в табл. 3. Видно, что использование дополнительного класса при обучении снижает значение метрики Dice на 0,01, при этом значительно повышается метрика F1 до 0,48, что говорит об улучшении способности алгоритма разделять объекты друг от друга и снизить количество ложных срабатываний. Добавление маски весов позволяет фокусироваться на более точном выделении границ полей, что выражается повышением Dice до 0,74. Использование метода инвариантности к аугментации вдобавок к предыдущим модификациям позволяет увеличить метрики Dice и F1 на 0,04 и 0,03, соответственно.

Таблица 3. Результаты тестирования модифицированной сети U-Net

Алгоритм	Dice	F1
Без модификаций	0,73	0,43
С классом узкая область между объектами	0,72	0,48
С классом узкая область между объектами + маска весов для границ	0,74	0,48
С классом узкая область между объектами + маска весов для границ + метод инвариантности к аугментации	0,78	0,51




Рис. 7. Зависимость изменения метрики Dice от номера эпохи на валидационном наборе для нейронных сетей U-Net и U-Net-m




Рис. 8. Сегментация спутникового изображения алгоритмом на основе сети U-Net-m:
а — оригинальное изображение; б — бинаризованная маска сегментации

Нейросетевой алгоритм, обученный с использованием всех предложенных модификаций, обозначим как U-Net-m. График изменения метрики Dice от номера эпохи на валидационном наборе, приведённый на рис. 7, дополнительно демонстрирует эффективность предложенных модификаций. Из него также следует, что предложенные изменения сокращают время обучения и позволяют получить алгоритм с высокой точностью сегментации уже после 180-й эпохи. Визуализация работы модифицированного алгоритма U-Net-m для участка поверхности Краснодарского края размером 30×30 км, содержащего значительное число сельхозугодий, представлена на рис. 8.

Заключение

В результате проведённого исследования показана достижимость повышения качества сегментации сельскохозяйственных полей по данным ДЗЗ, с фокусом на проблеме разделения смежных объектов, имеющих схожие спектральные характеристики. Для решения этой про-

блемы обоснована методика процесса обучения свёрточной нейронной сети U-Net, состоящая из адаптивной балансировки обучающих пакетов для устранения дисбаланса данных, введения дополнительного класса «узкая область между объектами», использования карты весов для границ сельхозугодий в функции потерь, а также применения метода инвариантности к аугментации. Результаты численного моделирования показали, что совокупность предложенных модификаций позволяет повысить точность сегментации с 0,68 до 0,78 по метрике Dice и с 0,39 до 0,51 по метрике детектирования F1 по сравнению с базовой архитектурой U-Net. Это подтверждает способность предложенного алгоритма корректно разделять сельскохозяйственные поля на отдельные объекты.

Полученные результаты имеют практическую значимость и могут быть применены в различных сферах агропромышленного комплекса и государственного управления для повышения эффективности и устойчивости процесса сельскохозяйственного производства.

Литература

1. Амирова Н. Р., Саргина Л. В., Кондратьева Я. Э. Цифровые технологии в сфере сельского хозяйства // ЦИТИСЭ. 2020. № 2. С. 266–280. DOI: 10.15350/2409-7616.2020.2.25.
2. Денисов П., Трошко К., Лупян Е. и др. Спутниковое дистанционное зондирование Земли в задаче установления границ земель сельскохозяйственного назначения // Землеустройство, кадастр и мониторинг земель. 2024. Т. 19. № 4. С. 227–232. DOI: 10.33920/sel-04-2404-04.
3. Ларионов Р. В., Сенников А. В., Хрящев В. В. Моделирование изменений лесного покрова по данным дистанционного зондирования земной поверхности // Автоматизация в промышленности. 2024. № 2. С. 32–35. DOI: 10.25728/avtprom.2024.02.09.
4. Николенко С., Кадушин А., Архангельская Е. Глубокое обучение. Погружение в мир нейронных сетей. СПб.: ИД «Питер», 2019. 480 с.
5. Скворцов Е., Скворцова Е., Санду И., Иовлев Г. Переход сельского хозяйства к цифровым, интеллектуальным и роботизированным технологиям // Экономика региона. 2018. № 3. С. 1014–1028. DOI: 10.17059/2018-3-23.
6. Толпин В. А., Барталев С. А., Ёлкина Е. С. и др. Информационная система VEGA-GEOGLAM — инструмент разработки методов и подходов использования данных спутникового дистанционного зондирования в интересах решения задач глобального сельскохозяйственного мониторинга // Современные проблемы дистанционного зондирования Земли из космоса. 2019. Т. 16. № 3. С. 183–197. DOI: 10.21046/2070-7401-2019-16-3-183-197.
7. Трошко К. А., Денисов П. В., Дунаева Е. А. и др. (2025а) Особенности развития озимых сельскохозяйственных культур в России в весенне-летний период 2025 года на основе данных дистанционного мониторинга // Современные проблемы дистанционного зондирования Земли из космоса. 2025. Т. 22. № 3. С. 321–328. DOI: 10.21046/2070-7401-2025-22-3-321-328.
8. Трошко К. А., Денисов П. В., Дунаева Е. А. и др. (2025б) Особенности развития сельскохозяйственных культур в России в 2025 году на основе данных дистанционного мониторинга // Современные проблемы дистанционного зондирования Земли из космоса. 2025. Т. 22. № 5. С. 449–456. DOI: 10.21046/2070-7401-2025-22-5-449-456.
9. Федоринов А. В., Волков С. Н., Денисов П. В. и др. Установление границ земель сельскохозяйственного назначения: опыт пилотных регионов. М.: РАДУГА, 2023. 420 с.
10. Федоринов А. В., Волков С. Н., Сорокина О. А. и др. Алгоритм установления границ категории земель сельскохозяйственного назначения сельскохозяйственных угодий для целей вовлечения земель в хозяйственный оборот. М.: РАДУГА, 2024. 224 с.
11. Belgiu M., Csillik O. Sentinel-2 cropland mapping using pixel-based and object-based time-weighted dynamic time warping analysis // Remote Sensing of Environment. 2018. V. 204. P. 509–523. DOI: 10.1016/j.rse.2017.10.005.
12. Gonzalez R. C., Woods R. E. Digital image processing. 4th ed. N. Y.: Pearson Publisher, 2017. 1192 p.
13. Kamilaris A., Prenafeta-Boldú F. X. A review of the use of convolutional neural networks in agriculture // J. Agricultural Science. 2018. V. 156. No. 3. P. 312–322. DOI: 10.1017/S0021859618000436.
14. Kamilaris A., Kartakoullis A., Prenafeta-Boldú F. X. A review on the practice of big data analysis in agriculture // Computers and Electronics in Agriculture. 2017. V. 143. P. 23–37. DOI: 10.1016/j.compag.2017.09.037.
15. Kornblith S., Norouzi M., Lee H., Hinton G. Similarity of neural network representations revisited // Proc. 36th Intern. Conf. on Machine Learning (ICML). 2019. V. 97. P. 3519–3529.

16. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional networks for biomedical image segmentation // Medical Image Computing and Computer-Assisted Intervention — MICCAI 2015. Lecture Notes in Computer Science. V. 9351. Cham: Springer, 2015. P. 234–241. DOI: 10.1007/978-3-319-24574-4_28.
17. Sedov A. G., Khryashchev V. V., Larionov R. V., Ostrovskaya A. A. Loss function selection in a problem of satellite image segmentation using convolutional neural network // 2019 Systems of Signal Synchronization, Generating and Processing in Telecommunications (SYNCHROINFO). 2019. 4 p. DOI: 10.1109/SYNCHROINFO.2019.8814279.
18. Tavera A., Arnaudo E., Masone C., Caputo B. Augmentation invariance and adaptive sampling in semantic segmentation of agricultural aerial images // Proc. IEEE/CVF Conf. on Computer Vision and Pattern Recognition Workshops (CVPRW). 2022. P. 1655–1664. DOI: 10.1109/CVPRW56347.2022.00172.
19. Waldner F., Diakogiannis F. I. Deep learning on edge: Extracting field boundaries from satellite images with a convolutional neural network // Remote Sensing of Environment. 2020. V. 245. Article 111741. DOI: 10.1016/j.rse.2020.111741.
20. Xu Y., Zhu Z., Guo M., Huang Y. Multiscale edge-guided network for accurate cultivated land parcel boundary extraction from remote sensing images // IEEE Trans. Geoscience and Remote Sensing. 2024. V. 62. Article 4501020. 20 p. DOI: 10.1109/TGRS.2023.3344122.

Improved delineation of contiguous agricultural fields in remote sensing image segmentation

R. V. Larionov, V. V. Khryashchev, A. L. Priorov

P. G. Demidov Yaroslavl State University, Yaroslavl 150003, Russia
E-mail: v.khryashchev@uniyar.ac.ru

The problem of automatic segmentation of agricultural lands in satellite images of remote sensing of the Earth is considered. The main focus of the research is aimed at solving the problem of separating adjacent objects with similar spectral characteristics, which is a common reason for merging several physically different fields into a single polygon using standard neural network approaches. Modern methods of field boundary allocation, including neural network architectures based on U-Net, are analyzed. To improve the quality of segmentation, a modified learning method is proposed, including adaptive balancing of training packages to eliminate data imbalance, the introduction of an additional class “narrow area between objects”, the use of a weight map for boundaries in the loss function, as well as the method of invariance to augmentation. Experiments on a set of images in the visible and near-infrared ranges from the Sentinel-2 satellite for the territory of the European part of Russia have shown that the combination of the proposed modifications makes it possible to increase the segmentation accuracy from 0.68 to 0.78 according to the Dice metric and from 0.39 to 0.51 according to the F1 detection metric, compared with the basic U-Net architecture. This confirms the ability of the proposed algorithm to correctly divide agricultural land into separate objects.

Keywords: remote sensing, image segmentation, farmland recognition, deep learning, convolutional neural network

Accepted: 17.04.2026

DOI: 10.21046/2070-7401-2026-23-4-51-62

References

1. Amirova N. R., Sargina L. V., Kondratyeva Ya. E., Digital technologies in agriculture, *CITISE*, 2020, No. 2, pp. 266–280 (in Russian), DOI: 10.15350/2409-7616.2020.2.25.
2. Denisov P. V., Troshko K. A., Lupyan E. A. et al., Satellite remote sensing for boundaries determination of agricultural lands, *Zemleustroistvo, kadastr i monitoring zemel'*, 2024, V. 19, No. 4, pp. 227–232 (in Russian), DOI: 10.33920/sel-04-2404-04.

3. Larionov R. V., Sennikov A. V., Khryashev V. V., Forest canopy changes modeling on the basis of remote surface sensing data, *J. Automation in Industry*, 2024, No. 2, pp. 32–35 (in Russian), DOI: 10.25728/avtprom.2024.02.09.
4. Nikolenko S., Kadurin A., Arkhangelskaya E., *Glubokoe obuchenie. Pogruzhenie v mir neironnykh setei* (Deep learning. Dive into the world of neural networks), Saint Petersburg: Piter Publishing House, 2019, 480 p. (in Russian).
5. Skvortsov E. A., Skvortsova E. G., Sandu I. S., Iovlev G. A., Transition of agriculture to digital, intellectual and robotics technologies, *Economy of Regions*, 2018, No. 3, pp. 1014–1028 (in Russian), DOI: 10.17059/2018-3-23.
6. Tolpin V. A., Bartalev S. A., Elkina E. S. et al., The VEGA-GEOGLAM information system: a tool for the development of methods and approaches to using satellite remote sensing data in problem-solving tasks of global agricultural monitoring, *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*, 2019, V. 16, No. 3, pp. 183–197 (in Russian), DOI: 10.21046/2070-7401-2019-16-3-183-197.
7. Troshko K. A., Denisov P. V., Dunaieva Ie. A. et al. (2025a), Development of winter crops in Russia in the spring-summer period of 2025 based on remote monitoring data, *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*, 2025, V. 22, No. 3, pp. 321–328 (in Russian), DOI: 10.21046/2070-7401-2025-22-3-321-328.
8. Troshko K. A., Denisov P. V., Dunaieva Ie. A. et al. (2025b), Development of agricultural crops in Russia in 2025 based on remote monitoring data, *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*, 2025, V. 22, No. 5, pp. 449–456 (in Russian), DOI: 10.21046/2070-7401-2025-22-5-449-456.
9. Fedorinov A. V., Volkov S. N., Denisov P. V. et al., *Ustanovlenie granits zemel' sel'skokhozyaistvennogo naznacheniya: opyt pilotnykh regionov* (Establishing boundaries of agricultural lands: Experience of pilot regions), Moscow: RADUGA, 2023, 420 p. (in Russian).
10. Fedorinov A. V., Volkov S. N., Sorokina O. A. et al., *Algoritm ustanovleniya granits kategorii zemel' sel'skokhozyaistvennogo naznacheniya sel'skokhozyaistvennykh ugodii dlya tselei vovlecheniya zemel' v khozyaistvennyi oborot* (Algorithm for establishing the boundaries of agricultural land category for the purposes of involving land into economic circulation), Moscow: RADUGA, 2024, 224 p. (in Russian).
11. Belgiu M., Csillik O., Sentinel-2 cropland mapping using pixel-based and object-based time-weighted dynamic time warping analysis, *Remote Sensing of Environment*, 2018, V. 204, pp. 509–523, DOI: 10.1016/j.rse.2017.10.005.
12. Gonzalez R. C., Woods R. E., *Digital image processing*, 4th ed., New York: Pearson Publisher, 2017, 1192 p.
13. Kamilaris A., Prenafeta-Boldú F. X., A review of the use of convolutional neural networks in agriculture, *J. Agricultural Science*, 2018, V. 156, No. 3, pp. 312–322, DOI: 10.1017/S0021859618000436.
14. Kamilaris A., Kartakoullis A., Prenafeta-Boldú F. X., A review on the practice of big data analysis in agriculture, *Computers and Electronics in Agriculture*, 2017, V. 143, pp. 23–37, DOI: 10.1016/j.compag.2017.09.037.
15. Kornblith S., Norouzi M., Lee H., Hinton G., Similarity of neural network representations revisited, *Proc. 36th Intern. Conf. on Machine Learning (ICML)*, 2019, V. 97, pp. 3519–3529.
16. Ronneberger O., Fischer P., Brox T., U-Net: Convolutional networks for biomedical image segmentation, In: *Medical Image Computing and Computer-Assisted Intervention — MICCAI 2015*, Lecture Notes in Computer Science, V. 9351, Cham: Springer, 2015, pp. 234–241, DOI: 10.1007/978-3-319-24574-4_28.
17. Sedov A. G., Khryashchev V. V., Larionov R. V., Ostrovskaya A. A., Loss function selection in a problem of satellite image segmentation using convolutional neural network, *2019 Systems of Signal Synchronization, Generating and Processing in Telecommunications (SYNCHROINFO)*, 2019, 4 p., DOI: 10.1109/SYNCHROINFO.2019.8814279.
18. Tavera A., Arnaudo E., Masone C., Caputo B., Augmentation invariance and adaptive sampling in semantic segmentation of agricultural aerial images, *Proc. IEEE/CVF Conf. on Computer Vision and Pattern Recognition Workshops (CVPRW)*, 2022, pp. 1655–1664, DOI: 10.1109/CVPRW56347.2022.00172.
19. Waldner F., Diakogiannis F. I., Deep learning on edge: Extracting field boundaries from satellite images with a convolutional neural network, *Remote Sensing of Environment*, 2020, V. 245, Article 111741, DOI: 10.1016/j.rse.2020.111741.
20. Xu Y., Zhu Z., Guo M., Huang Y., Multiscale edge-guided network for accurate cultivated land parcel boundary extraction from remote sensing images, *IEEE Trans. Geoscience and Remote Sensing*, 2024, V. 62, Article 4501020, 20 p., DOI: 10.1109/TGRS.2023.3344122.