

ПОЧВОВЕДЕНИЕ, ЗЕМЛЕУСТРОЙСТВО, КАДАСТР И МОНИТОРИНГ ЗЕМЕЛЬ

Оригинальная научная статья

УДК 332.2:528.8:004.85

<https://doi.org/10.26897/2949-4710-2026-4-2-6-02>



Новые технологии мониторинга земель на основе снимков с БПЛА, OpenDroneMap и нейросетевой модели DINOv3

Надежда Владимировна Гавриловская, Николай Александрович Мякшин,
Дмитрий Михайлович Бенин, Оксана Михайловна Кузина

Российский государственный аграрный университет –
МСХА имени К.А. Тимирязева, Москва, Россия

Автор, ответственный за переписку: Надежда Владимировна Гавриловская,
gavrilovskayanv@rgau-msha.ru

Аннотация

В условиях интенсификации сельскохозяйственного производства и роста антропогенной нагрузки на почвы особую значимость приобретает оперативный мониторинг земель, позволяющий выявлять изменения структуры землепользования и состояния земельных ресурсов на ранних стадиях. Традиционные наземные обследования обеспечивают высокую точность, но отличаются высокой трудоемкостью и ограниченным пространственным охватом, что затрудняет их применение для регулярного мониторинга больших территорий. Целью исследований являлась разработка и апробация сквозного программного пайплайна мониторинга земель, включающего в себя получение снимков с беспилотных летательных аппаратов (БПЛА), их фотограмметрическую обработку в OpenDroneMap с формированием ортофотопланов в формате GeoTIFF, разметку данных по классам землепользования, обучение с учителем сегментационной «головы» нейросети на основе предобученного трансформера DINOv3, семантическую сегментацию типов земель и экспорт результатов в геоинформационные системы (ГИС) в формате GeoJSON. Съемка проводилась с использованием БПЛА над сельскохозяйственными угодьями, характеризующимися сочетанием пахотных земель, залежей, луговой растительности, лесных массивов и застроенных территорий. Многокадровые перекрывающиеся изображения обрабатывались в OpenDroneMap с получением ортофотопланов и цифровых моделей поверхности; на их основе в настольной ГИС выполнялись векторная разметка полигонов классов землепользования и экспорт в формат GeoJSON. Всего было подготовлено 2000 размеченных фрагментов ортофотопланов, использованных для обучения и валидации «головы» нейросетевой модели. В качестве базового экстрактора признаков применен предобученный трансформер DINOv3, поверх которого реализован сегментационный декодер с обучением в режиме с учителем на размеченных данных. Качество работы модели оценивалось по метрикам полноты, точности, F1-меры и пересечения-объединения (IoU) для каждого класса земель, а также по средней IoU по всем классам. Результаты экспериментов показали, что предложенный подход обеспечивает высокую точность автоматизированной классификации основных типов землепользования на основе ортофотопланов с БПЛА и может быть использован для актуализации карт землепользования, кадастровой оценки и оперативного экологического мониторинга. Реализация пайплайна с использованием свободно распространяемого программного обеспечения (OpenDroneMap, QGIS) и открытых библиотек глубинного обучения делает его доступным для научных и производственных организаций.

Ключевые слова

Мониторинг земель, беспилотные летательные аппараты, OpenDroneMap, DINOv3, семантическая сегментация, землепользование, GeoJSON, ГИС, почвоведение, кадастр

Для цитирования

Гавриловская Н.В., Мякшин Н.А., Бенин Д.М., Кузина О.М. Новые технологии мониторинга земель на основе снимков с БПЛА, OpenDroneMap и нейросетевой модели DINOv3. *Тимирязевский биологический журнал*. 2026;4(2):602. <https://doi.org/10.26897/2949-4710-2026-4-2-6-02>

SOIL SCIENCE, LAND MANAGEMENT, LAND CADASTRE AND LAND MONITORING

Research article

<https://doi.org/10.26897/2949-4710-2026-4-2-6-02>



New land monitoring technologies based on UAV imagery, OpenDroneMap and the DINOv3 neural network model

Nadezhda V. Gavrilovskaya, Nikolay A. Myakshin,
Dmitriy M. Benin, Oksana M. Kuzina

Russian State Agrarian University – Moscow Timiryazev Agricultural Academy,
Moscow, Russia

Corresponding author: Nadezhda V. Gavrilovskaya, gavrilovskayanv@rgau-msha.ru

Annotation

In the context of the intensification of agricultural production and the growth of anthropogenic load on soils, operational land monitoring capable of detecting changes in land-use structure and land resource conditions at early stages has become critically important. Traditional ground-based surveys provide high accuracy but are labour-intensive and limited in spatial coverage, making them unsuitable for regular monitoring of large areas. The aim of this study was to develop and test an end-to-end software pipeline for land monitoring, encompassing the acquisition of unmanned aerial vehicle (UAV) imagery, photogrammetric processing in OpenDroneMap to generate orthomosaics in GeoTIFF format, data annotation by land-use classes, supervised training of a segmentation head based on the pre-trained DINOv3 transformer, semantic segmentation of land cover types, and export of results to Geographic information systems (GIS) in GeoJSON format. UAV surveys were conducted over agricultural lands comprising a mosaic of arable fields, fallow lands, grassland vegetation, forest areas, and built-up territories. Multi-frame overlapping images were processed in OpenDroneMap to produce orthomosaics and digital surface models; vector polygon annotation of land-use classes was performed in a desktop GIS environment, with subsequent export to GeoJSON. A total of 2,000 labeled orthomosaic tiles were prepared for training and validation of the neural network segmentation head. A pre-trained DINOv3 transformer was employed as the feature extractor, with a segmentation decoder trained in a supervised manner on the labeled dataset. Model performance was evaluated using recall, precision, F1-score, and intersection-over-union (IoU) metrics for each land-use class, as well as mean IoU across all classes. The experimental results demonstrate that the proposed approach achieves high accuracy in automated classification of major land-use types from UAV-derived orthomosaics, and can be applied to land-use map updating, cadastral assessment, and operational environmental monitoring. The implementation of the pipeline using open-source software (OpenDroneMap, QGIS) and open-source deep learning libraries makes it accessible to both research and production organisations.

Keywords

Land monitoring, unmanned aerial vehicles (UAV), OpenDroneMap, DINOv3, semantic segmentation, land use, GeoJSON, GIS, soil science, cadastre

For citation

Gavrilovskaya N.V., Myakshin N.A., Benin D.M., Kuzina O.M. New land monitoring technologies based on UAV imagery, OpenDroneMap and the DINOv3 neural network model. *Timiryazev Biological Journal*. 2026;4(2):602. <https://doi.org/10.26897/2949-4710-2026-4-2-6-02>

Введение

Introduction

В последние годы при решении задач мониторинга земель и почв все более широко применяются методы дистанционного зондирования в сочетании с беспилотными летательными аппаратами (БПЛА), обеспечивающими высокое пространственное разрешение и оперативность получения данных по сравнению со спутниковыми системами. Одновременно наблюдается быстрый прогресс в области методов глубокого обучения включая сверточные нейронные сети и архитектуры на основе трансформеров, которые успешно

используются для решения задач классификации и семантической сегментации земной поверхности по данным дистанционного зондирования.

Ряд исследований демонстрирует эффективность применения БПЛА и нейросетевых моделей для картирования землепользования, выявления изменений ландшафта, оценки состояния сельскохозяйственных угодий и почвенного покрова [1-4]. Вместе с тем многие работы либо фокусируются на отдельных стадиях обработки (например, только на фотограмметрической обработке или только на классификации), либо используют закрытое программное обеспечение, что затрудняет тиражирование и воспроизводимость результатов [5].

Особый интерес представляют модели на основе трансформеров – такие, как DINOv3, обеспечивающие высокое качество извлечения признаков и устойчивость к вариативности текстур и освещения, характерной для снимков с БПЛА. Их сочетание с обучаемой в режиме с учителем сегментационной «головой» позволяет решать задачи детальной классификации типов землепользования и состояния земель по ортофотопланам.

Цель исследований: разработка и экспериментальная оценка сквозного пайплайна мониторинга земель, включающего в себя все ключевые этапы: получение снимков с БПЛА, их фотограмметрическую обработку в OpenDroneMap, разметку данных по типам землепользования, обучение с учителем сегментационной «головы» нейросети поверх предобученного энкодера DINOv3 и экспорт результатов классификации в ГИС-системы в формате GeoJSON.

Для достижения поставленной цели решались следующие задачи:

1. Организовать получение и фотограмметрическую обработку снимков с БПЛА с формированием ортофотопланов и цифровых моделей поверхности.
2. Разработать схему разметки типов землепользования и подготовить датасет из ~2000 размеченных фрагментов ортофотопланов в формате GeoJSON.
3. Реализовать и обучить сегментационную «голову» нейросети на основе предобученного трансформера DINOv3 для семантической сегментации земель.
4. Оценить качество работы модели по стандартным метрикам и интегрировать результаты классификации в настольные ГИС посредством формата GeoJSON.

Методика исследований

Research method

В качестве объекта мониторинга рассмотрен аграрный ландшафт, предоставленный заказчиком, представленный сочетанием пахотных земель, залежей, естественных кормовых угодий, лесных массивов, водных объектов и застроенных территорий. Такое сочетание классов землепользования характерно для задач почвенно-аграрного мониторинга и кадастровой оценки земель.

Съемка выполнялась с использованием многороторного БПЛА, оснащенного RGB-камерой и приемником GNSS. Полеты планировались в специализированной программе с обеспечением продольного и поперечного перекрытий кадров не менее 75 и 60% соответственно, что необходимо для устойчивой фотограмметрической обработки. Высота полета подбиралась таким образом, чтобы

обеспечивать пространственное разрешение ортофотопланов порядка нескольких сантиметров на пиксель; съемка проводилась в безоблачную погоду около полудня для минимизации влияния теней.

Фотограмметрическая обработка снимков осуществлялась с использованием набора свободно распространяемого программного обеспечения OpenDroneMap (ODM/WebODM), реализующего полный цикл построения ортофотопланов и цифровых моделей рельефа по данным БПЛА. Стандартный технологический процесс включал в себя этапы вычленения ключевых точек, построения разреженного и плотного облака точек, генерации цифровой модели поверхности и построения ортофотоплана в формате GeoTIFF в единой системе координат.

Для объединения нескольких полетов и обеспечения сопоставимости результатов все проекты были приведены к единой системе координат. Полученные ортофотопланы служили в качестве основы для последующей разметки и обучения нейросетевой модели.

Разметка классов землепользования выполнялась в настольной ГИС (например, Google Earth Pro) по полученным ортофотопланам. На основе визуального анализа и доступных вспомогательных материалов были выделены классы, представленные в таблице 1.

Полигональные объекты каждого класса оцифровывались поверх ортофотоплана с соблюдением топологической корректности. Итоговые слои разметки экспортировались в формат GeoJSON, содержащий геометрию полигонов и атрибут «class», задающий тип землепользования.

Для обучения модели ортофотопланы автоматически нарезались на фрагменты фиксированного размера (например, 512 × 512 пикселей) с учетом соответствующих полигонов разметки; для каждого фрагмента формировалась маска классов в растровом формате. В итоговый датасет вошло 2000 размеченных фрагментов, которые были разделены на обучающую, валидационную и тестовую выборки (например, в пропорции 70/15/15) (рис. 1).

В качестве базового экстрактора признаков использовалась предобученная модель DINOv3, реализующая архитектуру Vision Transformer и обученная в режиме самосупервизии на масштабных наборах естественных изображений. Модель DINOv3 применялась в роли энкодера, преобразующего входные фрагменты ортофотопланов в многоканальные пространственные карты признаков.

Поверх энкодера была реализована сегментационная «голова», включающая в себя декодер с несколькими уровнями апсемплинга и блоками слияния признаков разных масштабов, аналогично

Таблица 1. Виды классификации земель.

Table 1. Types of land cover classification.

№	Вид классификации / <i>Type of classification</i>
1	пахотные земли (обрабатываемые поля) / <i>arable land (cultivated fields)</i>
2	залежи и многолетние травы / <i>fallow lands and perennial grasses</i>
3	лесные и древесно-кустарниковые насаждения / <i>forest and woody shrub vegetation</i>
4	застроенные территории (здания, дороги, площадки) / <i>built-up areas (buildings, roads, and paved surfaces)</i>
5	водные объекты / <i>water bodies</i>
6	прочие (открытый грунт, техногенные объекты и т.п.) / <i>other (open ground, man-made objects, etc.)</i>



Рисунок 1. Скриншот проекта в Google Earth Pro с ортофотопланом исследуемого участка.

Figure 1. Screenshot of the Google Earth Pro project showing the orthomosaic of the study area.

распространенным архитектурам семантической сегментации (U-образные сети, FPN-подобные структуры) (рис. 2). Обучение сегментационной «головы» проводилось в режиме с учителем на замороженном или частично дообучаемом энкодере DINOv3 (вариант выбирался эмпирически на основе результатов валидации).

В качестве функции потерь использовалась комбинация многоклассовой перекрестной энтропии и обобщенной Dice-функции, что позволяет одновременно учитывать баланс классов и качество перекрытия масок.

Обучение модели проводилось в среде Python с использованием одной из современных библиотек глубокого обучения (например, PyTorch или TensorFlow). Входные фрагменты ортофотопланов нормировались и при необходимости преобразовывались в пространственное разрешение, согласованное с конфигурацией DINOv3. Для повышения обобщающей способности использовались методы аугментации (случайные повороты, отражения, изменения яркости и контраста в разумных пределах).

Обучение сегментационной «головы» выполнялось в среде Python с использованием библиотеки глубокого обучения PyTorch [7] (табл. 2). В качестве оптимизатора применялся AdamW со скоростью обучения 1×10^{-4} ($lr = 1e-4$). Обучение проводилось в течение 50 эпох с размером батча 4. Для ускорения вычислений и снижения потребления памяти использовалась смешанная точность (Automatic Mixed Precision, torch.amp.GradScaler и torch.amp.autocast). В качестве функции потерь использовалась многоклассовая перекрестная энтропия (CrossEntropyLoss) с игнорированием класса фона (ignore_index = 0). Сохранение контрольной точки модели выполнялось по критерию минимума средней ошибки (best_loss) на обучающей выборке. Вычисления производились на GPU Nvidia A6000 (CUDA). Обучение выполнялось в течение заданного числа эпох с контролем метрик на валидационной выборке и использованием

алгоритма ранней остановки для предотвращения переобучения.

Для оценки качества семантической сегментации на тестовой выборке рассчитывались следующие метрики:

1. Общая точность (Overall Accuracy).
2. Полнота (Recall) и точность (Precision) по каждому классу.
3. F1-мера по каждому классу.
4. Метрика пересечения-объединения (IoU) по каждому классу и средняя IoU (mIoU).

Наиболее высокие значения IoU достигнуты для классов «Водные объекты» (IoU = 0.957) и «Лесные насаждения» (IoU = 0.918), что объясняется четкими спектральными и текстурными границами данных объектов на ортофотопланах. Наибольшие трудности классификации зафиксированы для классов «Залежи и многолетние травы» (IoU = 0.742) и «Прочие» (IoU = 0.704) ввиду высокой внутриклассовой вариативности растительного покрова. Общая точность модели (Overall Accuracy) составила 0.924, средняя IoU (mIoU) – 0.838, что соответствует уровню современных работ по семантической сегментации земельного покрова по данным БПЛА [2-4, 6].

В ходе обучения сегментационного декодера в течение 50 эпох наблюдалось устойчивое снижение функции потерь CrossEntropyLoss с 1.0212 (эпоха 1) до 0.2809 (эпоха 50), что составило снижение на 72.5% относительно начального значения. Наиболее интенсивное уменьшение потерь зафиксировано в первые 5 эпох (с 1.0212 до 0.5790), что свидетельствует об эффективности предобученных признаков энкодера DINOv3 как начального приближения для задачи семантической сегментации земельного покрова. Дальнейшее стабильное снижение функции потерь без признаков переобучения подтверждает корректность выбора скорости обучения ($lr = 1 \times 10^{-4}$) и архитектуры декодера.

Данные рисунка 3 демонстрируют сходимость модели в процессе обучения. Снижение значений функции потерь на обучающей




Рисунок 2. Схема пайплайна нейросетевой архитектуры (DINOv3-энкодер + сегментационный декодер).

Figure 2. Neural network architecture pipeline diagram (DINOv3 encoder + segmentation decoder).

Таблица 2. Метрики качества семантической сегментации на тестовой выборке.

Table 2. Semantic segmentation performance metrics on the test dataset.

Класс <i>Class</i>	Точность <i>Precision</i>	Полнота <i>Recall</i>	F1-мера <i>F1-score</i>	IoU
Пахотные земли <i>Arable land</i>	0.927	0.941	0.934	0.876
Залежи и многолетние травы <i>Fallow lands and perennial grasses</i>	0.861	0.843	0.852	0.742
Лесные насаждения <i>Forest vegetation</i>	0.953	0.962	0.957	0.918
Застроенные территории <i>Built-up areas</i>	0.912	0.904	0.908	0.832
Водные объекты <i>Water bodies</i>	0.976	0.981	0.978	0.957
Прочие <i>Other</i>	0.834	0.819	0.826	0.704
Среднее (масро) <i>Macro average</i>	0.911	0.908	0.909	0.838
Общая точность <i>Overall Accuracy</i>				0.924




Рисунок 3. Кривые обучения и валидации сегментационного декодера DINOv3 в течение 50 эпох.

Figure 3. Training and validation curves of the DINOv3 segmentation decoder over 50 epochs.

и валидационной выборках указывает на корректный выбор гиперпараметров и устойчивое обучение сегментационного декодера. Различие между кривыми Train Loss и Val Loss остается умеренным, что свидетельствует о достаточной обобщающей способности модели на данных дистанционного зондирования [8].

Сегментационные предсказания модели пересчитывались в векторные слои (полигональные объекты) с сохранением информации о классе и степени уверенности модели. Полученные векторные слои экспортировались в формат GeoJSON (рис. 4) и загружались в настольную ГИС для визуализации, наложения на другие пространственные данные (кадастровые кварталы, почвенные карты) и проведения пространственного анализа [9].

Результаты и их обсуждение

Results and discussion

В результате обучения на датасете из 2000 размеченных фрагментов модель на основе DINOv3 продемонстрировала высокие значения точности и IoU для основных классов землепользования, прежде всего – для пахотных земель, лесных массивов и водных объектов. Наиболее сложными для корректной классификации оказались переходные типы угодий – такие, как залежи и участки с мозаичным растительным покровом, где наблюдается значительное внутриклассовое разнообразие текстур и спектральных характеристик.

Сопоставление результатов модели на основе DINOv3 с более простыми базовыми архитектурами (например, классическими U-Net-подобными




Рисунок 4. Карта с классификацией земель после обучения модели.

Figure 4. Land cover classification map generated after model training.

сетями без трансформерного энкодера) показало улучшение усредненной IoU и F1-меры, особенно на классах с сложной пространственной структурой (лесные массивы, застроенные территории) [2-4]. Это согласуется с данными литературы о преимуществах трансформеров и гибридных CNN-Transformer архитектур в задачах сегментации покрытий земной поверхности по данным БПЛА.

Визуальный анализ карт классификации выявил высокую согласованность границ классов с реальными контурами полей и другими объектами землепользования, что особенно важно для решения задач кадастровой оценки и мониторинга структуры посевных площадей. При этом наиболее заметные ошибки приходились на участки с сильной неоднородностью микрорельефа, смешением культур и наличием локальных затенений (рис. 5). В подобных случаях модель иногда фрагментировала контуры полей или смешивала классы «Пахотные земли» и «Прочие».

Сопоставление результатов моделей с полевыми наблюдениями и высокодетальными космическими снимками подтвердило пригодность предложенного подхода для выявления изменений

землепользования (конверсия залежей в пашню, появление новых объектов застройки, изменение площади водных объектов) за счет регулярного повторения БПЛА-съемок и автоматизированной обработки.

Интеграция предсказанных карт землепользования в настольную ГИС через формат GeoJSON позволила использовать результаты сегментации как исходные слои для расчета площадей классов, построения статистики по землепользованию и анализа пространственных связей между типами земель и свойствами почв. В частности, возможны оценка доли пахотных земель на почвах различных генетических типов, выявление переуплотняемых участков, а также анализ динамики землепользования в контексте рекультивации нарушенных земель.

Использование открытого программного обеспечения (OpenDroneMap [10-12], QGIS) и пространственных форматов данных (GeoTIFF, GeoJSON) обеспечивает прозрачность и воспроизводимость всего процесса, а также облегчает интеграцию с существующими системами аграрного и экологического мониторинга.




Рисунок 5. Сегментация одного снимка после обучения модели.

Figure 5. Segmentation output of a single UAV image after model training.

Выводы

Conclusions

Разработан и реализован сквозной программный пайплайн мониторинга земель, включающий в себя получение снимков с БПЛА, их фотограмметрическую обработку в OpenDroneMap, разметку типов землепользования, обучение сегментационной «головы» нейросети на основе предобученной модели DINOv3 и экспорт результатов семантической сегментации в ГИС в формате GeoJSON, который можно использовать как SaaS продукт.

На датасете из ~2000 размеченных фрагментов ортофотопланов продемонстрирована возможность получения высококачественных карт землепользования с детальным выделением пахотных земель, лесных массивов, водных объектов и застроенных территорий; наибольшие трудности

классификации отмечены для переходных и мозаичных типов угодий.

Использование трансформерного энкодера DINOv3 в сочетании с обучаемой сегментационной «головой» обеспечивает улучшение метрик качества по сравнению с базовыми CNN-архитектурами, что согласуется с современными исследованиями в области глубинного обучения и дистанционного зондирования [2-4, 6].

Интеграция результатов сегментации в настольные ГИС через формат GeoJSON позволяет применять полученные карты при решении задач почвенного мониторинга, кадастровой оценки и анализа динамики землепользования, в том числе в составе существующих информационных систем аграрного профиля.

В дальнейшем планируется расширить размер и разнообразие обучающей выборки, включив мультиспектральные данные, а также

исследовать возможности адаптации обученной модели к другим регионам с отличающимися природно-почвенными и агротехническими условиями.

Список источников

1. Hoummaidi L.E., Larabi A., Alam K. Using unmanned aerial systems and deep learning for agriculture mapping in Dubai. *Heliyon*. 2021;7(10): e08154. <https://doi.org/10.1016/j.heliyon.2021.e08154>
2. Lu T., Wan L., Qi S., Gao M. Land Cover Classification of UAV Remote Sensing Based on Transformer-CNN Hybrid Architecture. *Sensors*. 2023;23(11):5288. <https://doi.org/10.3390/s23115288>
3. Dou Z., Akpokodje E., He Y. et al. DINOv3-Driven Semantic Segmentation for Landslide Mapping in Mountainous Regions. *Sensors*. 2026;26(2):406. <https://doi.org/10.3390/s26020406>
4. Pal K., Gupta N. Machine learning and deep learning approaches for soil classification: methods, challenges, and future prospects. *International Journal of Remote Sensing*. 2025;46(22):8488-8545. <https://doi.org/10.1080/01431161.2025.2570552>
5. Muratov S.M., Fazilova D.Sh. Monitoring forest fund lands using remote sensing combined with CollectEarth point data. *Vestnik of North-Eastern Federal University. Earth Sciences*. 2026;(1):5-18. <https://doi.org/10.25587/2587-8751-2026-1-5-1>
6. Шайтура С.В., Барбасов В.К., Минитаева А.М., Козаев Ю.П. Мониторинг сельскохозяйственных земель при помощи беспилотных летательных аппаратов. *Землеустройство, кадастр и мониторинг земель*. 2021;12:947-953. <https://doi.org/10.33920/sel-04-2112-10>
7. Imambi S., Prakash K.B., Kanagachidambaresan G.R. PyTorch. *Programming with TensorFlow*. Switzerland, Cham: Springer International Publishing. 2021:87-104. https://doi.org/10.1007/978-3-030-57077-4_10
8. Basheer S., Wang X., Farooque A.A. et al. Comparison of Land Use Land Cover Classifiers Using Different Satellite Imagery and Machine Learning Techniques. *Remote Sensing*. 2022;14(19):4978. <https://doi.org/10.3390/rs14194978>
9. Jia X., Hou D. Mapping soil arsenic pollution at a brownfield site using satellite hyperspectral imagery and machine learning. *Science of The Total Environment*. 2023;857:159387. <https://doi.org/10.1016/j.scitotenv.2022.159387>
10. Букреев К.Д. Использование open-source по для создания ортофотопланов. *Цифровые компетенции – сельскому хозяйству*. 2025:96-98.
11. Gbagir A.M.G., Ek K., Colpaert A. OpenDroneMap: Multi-Platform Performance Analysis. *Geographies*. 2023;3(3):446-458. <https://doi.org/10.3390/geographies3030023>
12. Zhang S., Gavrilovskaya N., Al Said N., Afandi W.S. A new approach to snow avalanche rescue using UAV pictures based on convolutional neural networks. *Journal of Real-Time Image Processing*. 2023;20(4):65. <https://doi.org/10.1007/s11554-023-01317-4>

Исследования выполнены в рамках проекта по созданию и развитию инжинирингового центра РГАУ-МСХА имени К.А. Тимирязева (соглашение № 075-15-2025-543 от 16 июня 2025 г.).

References

1. Hoummaidi L.E., Larabi A., Alam K. Using unmanned aerial systems and deep learning for agriculture mapping in Dubai. *Heliyon*. 2021;7(10): e08154. <https://doi.org/10.1016/j.heliyon.2021.e08154>
2. Lu T., Wan L., Qi S., Gao M. Land Cover Classification of UAV Remote Sensing Based on Transformer-CNN Hybrid Architecture. *Sensors*. 2023;23(11):5288. <https://doi.org/10.3390/s23115288>
3. Dou Z., Akpokodje E., He Y. et al. DINOv3-Driven Semantic Segmentation for Landslide Mapping in Mountainous Regions. *Sensors*. 2026;26(2):406. <https://doi.org/10.3390/s26020406>
4. Pal K., Gupta N. Machine learning and deep learning approaches for soil classification: methods, challenges, and future prospects. *International Journal of Remote Sensing*. 2025;46(22):8488-8545. <https://doi.org/10.1080/01431161.2025.2570552>
5. Muratov S.M., Fazilova D.Sh. Monitoring forest fund lands using remote sensing combined with CollectEarth point data. *Vestnik of North-Eastern Federal University. Earth Sciences*. 2026;(1):5-18. <https://doi.org/10.25587/2587-8751-2026-1-5-1>
6. Shaytura S.V., Barbasov V.K., Minitaeva A.M., Kozhaev Yu.P. Monitoring of agricultural land with unmanned aerial vehicles. *Zemleustroystvo, kadastr i monitoring zemel*. 2021;12:947-953. (In Russ.) <https://doi.org/10.33920/sel-04-2112-10>
7. Imambi S., Prakash K.B., Kanagachidambaresan G.R. PyTorch. *Programming with TensorFlow*. Switzerland, Cham: Springer International Publishing. 2021:87-104. https://doi.org/10.1007/978-3-030-57077-4_10
8. Basheer S., Wang X., Farooque A.A. et al. Comparison of Land Use Land Cover Classifiers Using Different Satellite Imagery and Machine Learning Techniques. *Remote Sensing*. 2022;14(19):4978. <https://doi.org/10.3390/rs14194978>
9. Jia X., Hou D. Mapping soil arsenic pollution at a brownfield site using satellite hyperspectral imagery and machine learning. *Science of The Total Environment*. 2023;857:159387. <https://doi.org/10.1016/j.scitotenv.2022.159387>
10. Bukreev K.D. Using open-source software for creating orthophotomaps. *Digital Competencies for Agriculture*. 2025: 96-98. (In Russ.)
11. Gbagir A.M.G., Ek K., Colpaert A. OpenDroneMap: Multi-Platform Performance Analysis. *Geographies*. 2023;3(3):446-458. <https://doi.org/10.3390/geographies3030023>
12. Zhang S., Gavrilovskaya N., Al Said N., Afandi W.S. A new approach to snow avalanche rescue using UAV pictures based on convolutional neural networks. *Journal of Real-Time Image Processing*. 2023;20(4):65. <https://doi.org/10.1007/s11554-023-01317-4>

Сведения об авторах

Надежда Владимировна Гавриловская, кандидат технических наук, доцент, и.о. заведующего кафедрой систем автоматизированного проектирования и инженерных расчетов, Российский государственный аграрный университет – МСХА имени К.А. Тимирязева; 127434, Россия, г. Москва, Тимирязевская ул., 49; gavrilovskayanv@rgau-msha.ru; <https://orcid.org/0000-0001-5060-7837>

Николай Александрович Мякшин, ассистент кафедры систем автоматизированного проектирования и инженерных расчетов, Российский государственный аграрный университет – МСХА имени К.А. Тимирязева; 127434, Россия, г. Москва, Тимирязевская ул., 49; miakshin_na@rgau-msha.ru; <https://orcid.org/0009-0009-2921-2895>

Дмитрий Михайлович Бенин, кандидат технических наук, доцент, доцент кафедры сельскохозяйственного водоснабжения, водоотведения, насосов и насосных станций, Российский государственный аграрный университет – МСХА имени К.А. Тимирязева; 127434, Россия, г. Москва, Тимирязевская ул., 49; dbenin@rgau-msha.ru; <https://orcid.org/0000-0003-1265-4071>

Оксана Михайловна Кузина, старший преподаватель кафедры сельскохозяйственных мелиораций, Российский государственный аграрный университет – МСХА имени К.А. Тимирязева; 127434, Россия, г. Москва, Тимирязевская ул., 49; kuzina_om@rgau-msha.ru; <https://orcid.org/0000-0001-9229-4306>

Конфликт интересов

Авторы заявляют об отсутствии конфликта интересов.

Статья поступила в редакцию 25.05.2026
Одобрена после рецензирования 24.06.2026
Принята к публикации 24.06.2026

Information about the authors

Nadezhda V. Gavrilovskaya, CSc (Eng), Associate Professor, Acting Head of the Department of Computer-Aided Design Systems and Engineering Analysis, Russian State Agrarian University – Moscow Timiryazev Agricultural Academy; 49 Timiryazevskaya St., Moscow, 127434, Russian Federation; gavrilovskayanv@rgau-msha.ru; <https://orcid.org/0000-0001-5060-7837>

Nikolay A. Myakshin, Assistant at the Department of Computer-Aided Design Systems and Engineering Analysis, Russian State Agrarian University – Moscow Timiryazev Agricultural Academy; 49 Timiryazevskaya St., Moscow, 127434, Russian Federation; miakshin_na@rgau-msha.ru; <https://orcid.org/0009-0009-2921-2895>

Dmitriy M. Benin, CSc (Eng), Associate Professor, Associate Professor at the Department of Agricultural Water Supply, Sanitation, Pumps and Pumping Stations, Russian State Agrarian University – Moscow Timiryazev Agricultural Academy; 49 Timiryazevskaya St., Moscow, 127434, Russian Federation; dbenin@rgau-msha.ru; <https://orcid.org/0000-0003-1265-4071>

Oksana M. Kuzina, Senior Lecturer at the Department of Agricultural Land Reclamation, Russian State Agrarian University – Moscow Timiryazev Agricultural Academy; 49 Timiryazevskaya St., Moscow, 127434, Russian Federation; kuzina_om@rgau-msha.ru; <https://orcid.org/0000-0001-9229-4306>

Conflict of interests

The authors declare no relevant conflict of interests.

The article was submitted to the editorial office
May 25, 2026
Approved after reviewing June 24, 2026
Accepted for publication June 24, 2026