

## Выделение дражных отвалов на спутниковых снимках методами компьютерного зрения и машинного обучения

Р. А. Секриеру, К. С. Цыгулёв, С. А. Орлов, С. И. Смагин, Т. В. Кожевникова

*Вычислительный центр ДВО РАН, Хабаровск, 680000, Россия  
E-mail: roma.sekrieru@gmail.com*

Представлены результаты исследования возможностей автоматизированного выделения территорий золотодобычи с дражными отвалами на основе спутниковых данных с применением методов компьютерного зрения и машинного обучения. Актуальность исследования обусловлена востребованностью оценки запасов техногенного сырья на удалённых и труднодоступных территориях для возможной повторной переработки. В исследовании использованы мультиспектральные снимки спутников Sentinel-2 территории Дальневосточного федерального округа России за 2018–2024 гг. Рассмотрены два подхода к решению задачи: пиксель-ориентированный, основанный на моделях полносвязных нейронных сетей и случайного леса, и объектно-ориентированный с применением свёрточных и трансформерной нейронных сетей. Проведён анализ информативности спектральных каналов методом градиентно-взвешенной атрибуции, что позволило оптимизировать входные данные моделей. Для выделения отдельных отвалов в пределах идентифицированных территорий предложено применение фильтра Франги, выявляющего характерные для дражных отвалов линейные структуры.

**Ключевые слова:** дистанционное зондирование Земли, компьютерное зрение, машинное обучение, золотодобыча, дражный метод, отвалы

Одобрена к печати: 11.06.2026

DOI: 10.21046/2070-7401-2026-23-4-89-102

### Введение

Добыча золота — это одна из ключевых отраслей горнодобывающей промышленности, занимающая важное место в экономике России. Основные золотоносные районы сосредоточены в Сибири и на Дальнем Востоке в таких регионах, как Красноярский край, Магаданская область, республика Саха (Якутия) и Хабаровский край. По мере развития технологий добычи полезных ископаемых появилась возможность разрабатывать отходы (отвалы) выведенных из эксплуатации месторождений. Они оказывают существенное влияние на окружающую среду — в почву и воду попадают тяжёлые металлы, кислоты и другие вредные вещества (Abu Qdais et al., 2018; Shkolnyi et al., 2024). При этом переработка отвалов может иметь как экологическую, так и экономическую выгоду (Чуркин, Гилярова, 2020).

Для реализации этой возможности необходимо провести повторную разведку территории. Из-за удалённости некоторых месторождений и отсутствия транспортной инфраструктуры это может быть затратно как с экономической точки зрения, так и по времени. По этой причине актуальным решением становится применение методов и технологий дистанционного мониторинга районов добычи полезных ископаемых, использующих данные космических аппаратов (Литвинцев и др., 2021; Werner et al., 2020).

Появление спутников, ведущих съёмку поверхности Земли в широком диапазоне электромагнитного спектра с высоким пространственным и временным разрешением (Sentinel-2, Landsat-8, -9, WorldView, Aster и др.), позволяет дополнить или заменить традиционные методы мониторинга алгоритмами анализа спутниковых данных. В отличие от традиционных полевых методов, требующих значительных временных затрат и физического присутствия специалистов на местности, спутниковые технологии обеспечивают практически непрерывное наблюдение за обширными территориями с интервалами, ограниченными лишь погодными условиями и техническими характеристиками орбитальных систем.

Многоспектральность спутниковых данных даёт возможность получать нужную информацию об интересующих участках поверхности Земли и проводить количественный и каче-

ственный анализ состояния природных ресурсов и экосистем (Liu et al., 2018; Traore et al., 2020). Также спутниковые данные в разных спектрах могут комбинироваться с данными геофизических исследований, геохимических анализов почв, цифровых моделей рельефа и т.д., что позволяет создавать содержательные комплексные модели (Калашник и др., 2022). При наземном исследовании используются более точные и недоступные при дистанционном зондировании инструменты. Однако спутниковые данные позволяют экстраполировать результаты таких исследований на большую территорию. Таким образом, совместное использование данных дистанционного зондирования Земли, включая данные беспилотных летательных аппаратов и спутников, с результатами наземных исследований позволяет создавать более точные модели (Alsayed, Nabawy, 2023).

Одними из наиболее часто применяемых методов в области анализа спутниковых данных представляются методы компьютерного зрения и машинного обучения (Lin et al., 2024; Shirmard et al., 2022; Yao et al., 2024). Их использование обусловлено масштабом исследуемых процессов (например, загрязнения рек), необходимостью обработки большого объема данных, большим числом параметров, описывающих эти процессы, неоднородностью получаемых данных, связанной с пространственным разрешением снимков, а также разнообразием источников спутниковых данных.

В задачах мониторинга добычи золота высокую эффективность демонстрируют классические алгоритмы машинного обучения (Nursamsi et al., 2024). Модель случайного леса (*англ.* random forest) используется для прогнозирования расширения добычи с учётом инфраструктуры (Larrea-Gallegos et al., 2023), выявления изменений земельного покрова по временным рядам данных спутниковых снимков (Fonseca et al., 2024), оценки перспективности разработки месторождений золота (Lachaud et al., 2023). Свёрточные нейронные сети (СНС) применяются для мониторинга и сегментации объектов на спутниковых снимках. Они широко используются для картирования различных объектов и явлений (Gallwey et al., 2020; Zhu et al., 2024), включая выделение дорог, карьеров и т.д. (Kou et al., 2024; Li et al., 2024; Peng et al., 2025; Sahu, Dash, 2024; Zhou et al., 2024).

Основные способы определения отвалов на спутниковых снимках основаны на спектральных индексах и применении моделей машинного обучения. Спектральные индексы используют различные комбинации каналов для выделения характерных особенностей отвалов. Точность этого способа зависит от сложности ландшафта и атмосферных условий. Также ограничениями выступают ложные срабатывания на обнажённой поверхности.

Традиционные модели машинного обучения (например, случайного леса) показывают высокую точность выделения отвалов на относительно небольших обучающих выборках. Однако их эффективность существенно зависит от качества обучающих данных. Они показывают низкую точность при сложной геометрии отвалов.

Использование моделей глубокого обучения представляет собой современное направление в автоматическом картировании горнодобывающих территорий. Такие модели показывают лучшую точность в сравнении с другими способами (Chen et al., 2025), но при этом для их применения требуется большой объём обучающих данных.

Несмотря на то, что компьютерное зрение и модели машинного обучения активно используются при дистанционном зондировании объектов горнопромышленного комплекса, вопрос их применения для выделения дражных отвалов освещён недостаточно.

Цель данной работы заключается в разработке, программной реализации и апробации алгоритмов анализа спутниковых снимков с помощью технологий компьютерного зрения и машинного обучения, позволяющих автоматизировать процесс выделения дражных отвалов.

## Исходные данные

Информация о местах проведения дражных работ получена из «Государственного реестра участков недр, предоставленных в пользование, и лицензий на пользование недрами» для всех субъектов Дальневосточного федерального округа РФ. Список рек, выбранных для формирования набора данных, представлен в *табл. 1*.

Исходные данные получены со спутников Sentinel-2. Было отобрано 180 снимков за период проведения съёмок — с мая по сентябрь 2018–2024 гг. В весенне-осеннее время дражные отвалы хорошо контрастируют с окружающей средой. Снимки имеют второй уровень обработки. На этом уровне обработки проводится атмосферная коррекция снимков. При этом снижается влияние аэрозолей и водяного пара на рассчитываемые значения отражательной способности земной поверхности. Список используемых спектральных каналов представлен в *табл. 2*. Все каналы с разрешением 20 м были передискретизированы к пространственному разрешению 10 м. На *рис. 1* показаны RGB-снимки территорий, занятых дражными отвалами.

Таблица 1. Список выбранных рек

| Субъект РФ               | Названия рек                                                                               |
|--------------------------|--------------------------------------------------------------------------------------------|
| Амурская область         | Вторая Гарь, Желтулак 1-й, Уркума, Коровина, Джалинда, Дубакит, Большой Караурак, Селемджа |
| Забайкальский край       | Итака, Чёрный Урюм, Средняя Борзя                                                          |
| Республика Саха (Якутия) | Большой Куранах, Томмот                                                                    |
| Хабаровский край         | Олга, Семитка                                                                              |
| Иркутская область        | Большая Бульбукта                                                                          |

Таблица 2. Используемые каналы спутниковых снимков Sentinel-2

| Канал       | Разрешение, м | Длина волны, мкм | Канал            | Разрешение, м | Длина волны, мкм |
|-------------|---------------|------------------|------------------|---------------|------------------|
| B2 (Blue)   | 10            | 0,458–0,523      | B3 (Green)       | 10            | 0,543–0,578      |
| B4 (Red)    | 10            | 0,650–0,680      | B5 (VRE)         | 20            | 0,698–0,713      |
| B6 (VRE)    | 20            | 0,733–0,748      | B7 (VRE)         | 20            | 0,773–0,793      |
| B8 (NIR)    | 10            | 0,785–0,900      | B11 (SWIR1)      | 20            | 1,565–1,655      |
| B12 (SWIR2) | 20            | 2,100–2,280      | B8A (NIR narrow) | 20            | 0,855–0,875      |

Примечание: VRE (*англ.* vegetation red edge), NIR (*англ.* near infrared), SWIR (*англ.* short wave infrared).




Рис. 1. Снимки RGB территорий с дражными отвалами на реках Большой Куранах (слева) и Коболдо (справа)

При формировании масок областей, занятых дражными отвалами, их границы определяются с учётом значений NDBSI (*англ.* Normalized Difference Bare Soil Index) и NDWI (*англ.* Normalized Difference Water Index):

$$\text{NDBSI} = \frac{\text{SWIR1} + \text{Red} - \text{NIR} - \text{Blue}}{\text{SWIR1} + \text{Red} + \text{NIR} + \text{Blue}}, \quad \text{NDWI} = \frac{\text{Green} - \text{NIR}}{\text{Green} + \text{NIR}}.$$

Показатель NDBSI — это индекс, разработанный для идентификации и картирования участков обнажённой почвы. Он применяется для разграничения областей с дражными отвалами от территорий, покрытых растительностью. Индекс NDWI позволяет исключить водоёмы, если они занимают большую площадь внутри области с дражными отвалами или мешают выделению её границ.

При разметке территорий с отвалами использовалась комбинация каналов Red-NIR-SWIR. Она позволяет обнаружить повышенную концентрацию соединений тяжёлых металлов, в первую очередь гидроксидов Fe, Mn, Cu, возникших в результате гипергенных изменений первичных минералов, и может указывать на объекты размещения отходов горнопромышленного комплекса (Галченко и др., 2024).

Для повышения контрастности областей с дражными отвалами проводится бинаризация по значениям индексов NDBSI и NDWI (Ngom et al., 2022). Проблемными для выделения остаются территории, где нет заметной границы между дражными отвалами и другими типами поверхности. В таком случае применяется операция морфологического закрытия. Она состоит из последовательного использования операций эрозии и дилатации (Gao et al., 2020), что позволяет устранить пустые области внутри границ территории с отвалами. На рис. 2 приведён пример графического представления индекса NDBSI, бинаризации по его значениям и применения операции закрытия для выделения областей с дражными отвалами.




Рис. 2. Выделение границ области с дражными отвалами с применением бинаризации и операции морфологического закрытия

В итоге заросшие территории были размечены вручную, а участки активной или недавней разработки, которые ещё не заросли, размечались с использованием индексов NDBSI, NDWI и операции морфологического закрытия с последующей ручной корректировкой масок.

## Модели и методы

В работе рассматриваются два подхода к выделению дражных отвалов по данным дистанционного зондирования Земли, которые можно охарактеризовать как пиксель-ориентированный и объектно-ориентированный (Kou et al., 2024).

Первый подход основан на анализе яркости пикселей, характеризующей интенсивность отражённого света в определённом диапазоне электромагнитного спектра. Для реализации этого подхода выбраны модели полносвязных нейронных сетей (ПНС) и случайного леса.

Второй подход опирается на поиск и выделение искомым объектов по таким визуальным характеристикам, как геометрические формы, распределение цветов, градиент яркости и т. д. В этом случае применяются модели, основанные на СНС. В отличие от моделей, используемых в первом подходе, СНС позволяют анализировать пространственную структуру снимка. Второй подход разбивается на два этапа. На первом этапе выполняется сегментация терри-

торий, потенциально содержащих дражные отвалы, с использованием моделей глубокого обучения. Этот этап позволяет локализовать области с нарушенным почвенным покровом и характерной для золотодобычи пространственной структурой. На втором этапе применяются алгоритмы выделения линейных структур для идентификации заросших отвалов.

Использование мультиспектральных входных данных повышает возможность выделять объекты, которые имеют слабо выраженные визуальные характеристики в некоторых спектральных диапазонах. Для реализации данного подхода выбраны модели СНС U-Net Attention (Oktay et al., 2018), DeepLabV3+ (Chen et al., 2018) и Segformer (Xie et al., 2021). Модели U-Net Attention и DeepLabV3+ часто используются в задачах семантической сегментации горных территорий (Gallwey et al., 2020).

Модель U-Net Attention способна достигать высокой точности выделения объектов при ограниченном наборе данных, что актуально для дражных отвалов. На них долго восстанавливается растительность, поэтому они практически не меняются из года в год. В связи с этим, несмотря на наличие большого количества спутниковых снимков, для составления хорошего набора данных подходит лишь малая их часть.

DeepLabV3+ представляет собой модель, основанную на СНС, для решения задач сегментации. Её основным отличием становится использование расширенной свёртки и пирамидального объединения (пулинга). В расширенной свёртке, в отличие от стандартной, ядро свёртки применяется не только к смежным пикселям, но и к расположенным на заданном интервале друг от друга. Таким образом расширенная свёртка увеличивает рецептивное поле модели. Пирамидальный пулинг позволяет анализировать объекты в разных масштабах. Перечисленные особенности модели важны в связи с тем, что дражные отвалы могут занимать площадь в несколько десятков квадратных километров, резко сужаясь или расширяясь на некоторых участках.

Segformer — относительно новая модель, основанная на трансформерах, адаптированных для задачи сегментации. В отличие от СНС, трансформеры способны выделять глобальные и локальные различия между частями изображения с помощью алгоритма самовнимания. Этот алгоритм вычисляет весовые коэффициенты, определяющие значимость каждого пикселя относительно всех остальных. Это может быть важно для выделения границ объектов по спутниковым снимкам, поскольку самовнимание позволяет фокусироваться на областях, где с большей вероятностью находится искомый объект.

При обучении используемых моделей каждый снимок из набора данных был разделён на части размером 384×384 пикселя. Данные были разделены на обучающую и валидационную выборки таким образом, что снимки разных рек входят только в один из этих наборов. При этом и обучающая, и валидационная выборка содержит как участки с заросшими, так и неза-росшими отвалами.

Таким образом, итоговый набор данных состоял из 3977 частей в тренировочной выборке и 1358 частей в валидационной. Все части содержали участки с отвалами. В качестве аугментаций применялись вертикальное и горизонтальное отражение, а также повороты на угол от 0 до 270°.

В качестве функции ошибки тестировались dice loss, boundary loss, focal loss и FocalTversky loss (Azad et al., 2023). Лучший результат получен при использовании последней функции ошибки:

$$\text{FocalTversky} = \left( 1 - \frac{\text{TP}}{\text{TP} + \alpha \text{FP} + \beta \text{FN}} \right)^\gamma,$$

где параметры  $\alpha$ ,  $\beta$  и  $\gamma$  равнялись 0,2, 0,8 и 1,33 соответственно. Здесь TP (*англ.* True Positive) — это количество пикселей, которые правильно классифицированы как принадлежащие к целевому классу; TN (*англ.* True Negative) — количество пикселей, которые правильно классифицированы как принадлежащие к нецелевому классу (фон); FP (*англ.* False Positive) — количество пикселей, которые ошибочно классифицированы как принадлежащие к целевому классу; FN (*англ.* False Negative) — количество пикселей, которые ошибочно классифицированы как принадлежащие к фону.

Выбранные трансформерные и свёрточные модели были обучены со случайной инициализацией весов и использованием предобученных весов. Тестировались энкодеры resnet 18, 34, 50, mit-b0, mit-b3, mobilenet\_v2. Вклад каналов в результат оценивался методом градиентно-взвешенной атрибуции входа (Sundararajan et al., 2017). Для каждого канала вычислялось среднее значение модуля произведения входных значений и градиента функции потерь, масштабированное на стандартное отклонение. Нормализация позволяет учесть различия в динамических диапазонах спектральных каналов, предотвращая смещение к каналам с высокой отражательной способностью.

После установления территории с отвалами необходимо выделить непосредственно отвалы, которые на ней расположены. Основная проблема заключается в схожести отвалов и обнажённой поверхности, такой как песчаные отмели, каменистые осыпи, а также техногенно-нарушенные участки (дороги, котлованы и т.д.). При длительном зарастании отвалы всё больше сглаживаются под воздействием различных эрозионных процессов, покрываются растительностью и становятся практически неотличимы от другой поверхности, покрытой растительностью. Если отвалы ещё не заросли, нет универсального индекса, который позволяет их выделить. Особенно это актуально для дражного метода разработки, так как отвалы могут занимать разную площадь в сравнении со всей областью разработки. Для выделения незаросших отвалов использовались индексы NDBSI, NDWI, NDVI (*англ.* Normalized Difference Vegetation Index), а также отношения разных каналов, которые показывают повышенную концентрацию гидроксильных минералов, железа и т.д. Для выявления заросших отвалов применялся фильтр Франги (Jerman et al., 2015).

Фильтр Франги представляет собой метод выделения трубчатых структур на медицинских изображениях, основанный на анализе собственных значений матрицы Гессе (матрицы вторых частных производных интенсивности изображения). Дражные отвалы имеют вытянутую структуру, что обосновывает применение этого фильтра. Для использования фильтра задействовались каналы с пространственным разрешением 10 м. Они были сжаты в один канал с помощью алгоритма анализа главных компонент (Jolliffe, Cadima, 2016).

## Результаты

Апробация рассмотренных методов проводилась с использованием данных Sentinel-2 за 2018–2024 гг. для территории Дальневосточного федерального округа. Сравнение моделей выполнялось последовательно на задачах попиксельной классификации и семантической сегментации. Выделение отвалов проводилось на местах добычи вблизи села Бриакан в Хабаровском крае и на реке Средняя Борзя в Якутии.

Модель случайного леса была обучена со стандартными параметрами, за исключением числа деревьев. Применение этой модели показало лучший результат классификации при значении 50 деревьев. Модель ПНС, помимо входного и выходного слоёв, включала ещё три внутренних слоя по 64 нейрона каждый. При обучении моделей проводилась кросс-валидация с разделением выборки на пять групп. На *рис. 3* представлены результаты применения моделей к снимкам Sentinel-2. Оценка точности классификации проведена по метрикам Precision, Recall, F1:

$$\text{Precision} = \frac{TP}{TP + FP}, \quad \text{Recall} = \frac{TP}{TP + FN}, \quad F1 = \frac{TP}{TP + 0,5(FP + FN)}.$$

В *табл. 3* представлены значения метрик точности моделей. Лучшую точность классификации отвалов показала модель полносвязной нейронной сети на снимках Sentinel-2. Для классификации отвалов на снимках Sentinel-2 предпочтительнее использовать ПНС.

В результате традиционные модели обучаются распознавать спектральные характеристики обнажённой поверхности в целом, а не только дражные отвалы. Такие модели хорошо выделяют общую территорию с нарушенным почвенным покровом, но недостаточно эффективны для определения отдельных отвалов внутри территории разработки и разграничения заросших отвалов от естественной растительности.




Рис. 3. Классификация пикселей снимков Sentinel-2 с применением моделей ПНС и случайного леса

Таблица 3. Оценка точности классификации моделей случайного леса и ПНС

| Случайный лес |           |       | Полносвязная нейронная сеть |           |       |
|---------------|-----------|-------|-----------------------------|-----------|-------|
| Recall        | Precision | F1    | Recall                      | Precision | F1    |
| 0,462         | 0,760     | 0,575 | 0,589                       | 0,801     | 0,679 |

В табл. 3 представлены метрики точности моделей трансформерной и свёрточных сетей на тестовой выборке. Кроме упомянутых ранее метрик, также использовались IoU (англ. Intersection Over Union) и AP (англ. Average Precision):

$$\text{IoU} = \frac{\text{TP}}{\text{TP} + \text{FP} + \text{FN}}, \quad \text{AP} = \sum_{n=1}^N (R_n - R_{n-1}) P_n,$$

где  $P_n$ ,  $R_n$  — это значения Precision и Recall, найденные при разных порогах бинаризации. При переборе  $N$  порогов получается кривая Precision-Recall.

Диаграмма вклада каналов, построенная методом градиентно-взвешенной атрибуции входа, изображена на рис. 4.

Модели с предобученными весами показывают более высокие результаты. Это выражается в меньшем числе ложных срабатываний, когда территорией с дражными отвалами считается урбанизированная или гористая местность с частичным лесным покрытием.

В соответствии с вкладом каналов обучающая выборка была изменена и включала каналы B3, B5, B6, B8, B11, B8A. В качестве предобученных энкодеров использовались mobilenetv2 для U-Net Attention и DeepLabV3+ и mit-b0 для Segformer. В табл. 4 представлены оценки точности результатов работы моделей. Значения точности получены для открытых и заросших отвалов вместе, без разделения на отдельные классы. Дальнейшее сокращение числа каналов приводит к снижению точности сегментации. Это может быть обусловлено не важностью отдельных каналов, а ошибками в обучающей выборке. На рис. 5 представлены результаты применения моделей СНС к снимкам Sentinel-2.




Рис. 4. Диаграмма вклада каналов

Таблица 4. Оценки точности классификации моделями СНС

| Модель          | Recall | Precision | F1    | IoU   | AP    |
|-----------------|--------|-----------|-------|-------|-------|
| U-Net Attention | 0,920  | 0,839     | 0,872 | 0,782 | 0,813 |
| DeepLabV3+      | 0,925  | 0,843     | 0,874 | 0,786 | 0,928 |
| Segformer       | 0,958  | 0,820     | 0,877 | 0,789 | 0,929 |




Рис. 5. Классификация пикселей снимков Sentinel-2 с применением моделей СНС

На рис. 6 представлены результаты применения фильтра Франги с промежуточным шагом в виде сегментации с помощью обученной модели нейронной сети для выделения отвалов. Красным цветом отмечены потенциальные дражные отвалы. Применение фильтра Франги позволяет определить отвалы, но при этом всё ещё выделяются лишние пиксели, которые не относятся к отвалам.




Рис. 6. Выделение дражных отвалов с применением СНС и фильтра Франги

## Заключение

В работе представлены результаты исследования методов автоматизированного выделения дражных отвалов золотодобычи по мультиспектральным спутниковым снимкам Sentinel-2 на территории Дальневосточного федерального округа. Исследование охватывает территории активной и исторической золотодобычи в Амурской области, Забайкальском крае, Республике Саха (Якутия), Хабаровском крае и Иркутской области за 2018–2024 гг.

Проведено сравнение двух подходов к решению задачи сегментации: пиксель-ориентированного, основанного на моделях ПНС и случайного леса, и объектно-ориентированного с использованием моделей глубокого обучения (U-Net Attention, DeepLabV3+, Segformer). Пиксель-ориентированный подход показал умеренную точность классификации на снимках Sentinel-2, однако результаты характеризуются высоким уровнем шума и нечёткими границами выделяемых объектов, что ограничивает их практическое применение.

Объектно-ориентированный подход продемонстрировал сопоставимую точность сегментации всеми моделями. Лучшие результаты достигнуты моделью Segformer. Анализ вклада спектральных каналов методом градиентно-взвешенной атрибуции входа позволил сократить число каналов входных данных до шести (B3, B5, B6, B8, B11, B8A) без существенной потери точности.

Для выделения непосредственно дражных отвалов внутри идентифицированных территорий предложено применение фильтра Франги для выделения линейных структур. Он позволяет определять как свежие отвалы, так и заросшие, однако требуется дальнейшая корректировка результата.

Полученные результаты показывают возможность автоматизации выделения дражных отвалов с использованием спутниковых снимков, что особенно ценно для мониторинга удалённых территорий.

Практическая значимость работы заключается в возможности оперативного картирования территорий с дражными отвалами на больших площадях труднодоступных регионов без необходимости проведения полевых работ. Полученные результаты могут служить основой для последующей оценки запасов техногенного сырья и принятия решений о целесообразности повторной переработки отвалов.

Результаты исследований, связанные с обучением моделей нейронных сетей (U-Net Attention, DeepLabV3+, Segformer), получены за счёт средств гранта Российского научного фонда (проект № 24-11-20029, <https://rscf.ru/project/24-11-20029/>). Работа над остальной частью статьи выполнена в рамках государственного задания Минобрнауки России для Хабаровского федерального исследовательского центра ДВО РАН (номер госрегистрации темы 122012100026-1).

## Литература

1. Галченко Ю.П., Озарян Ю.А., Кожевникова Т.В., Окладников В.Е. Идентификация объектов размещения отходов горнопромышленного комплекса по данным дистанционного зондирования // Физико-техн. проблемы разработки полезных ископаемых. 2024. № 4. С. 173–179. DOI: 10.15372/FTPRI20240415.
2. Калашиник А.И., Максимов Д.А., Калашиник Н.А. и др. Многоуровневые комплексные исследования и мониторинг хвостохранилищ горнодобывающих предприятий северо-западной части Российского сектора Арктики. Апатиты: ФИЦ КНЦ РАН, 2022. 250 с. DOI: 10.37614/978.5.91137.465.5.
3. Литвинцев В.С., Усиков В.И., Озарян Ю.А., Алексеев В.С. Метод дистанционного зондирования Земли в составе работ по оценке объемов техногенного сырья и экологической обстановки при эксплуатации россыпей // Георесурсы. 2021. Т. 23. № 4. С. 116–123. DOI: 10.18599/grs.2021.4.13.
4. Чуркин О.Е., Гилярова А.А. Освоение отходов горного производства как инвестиционное направление развития горнорудной промышленности Кольского полуострова // Экономика, предпринимательство и право. 2020. Т. 10. № 3. С. 905–916. DOI: 10.18334/epp.10.3.100742.
5. Abu Qdais H., Begday I.V., Katorgin I.Yu. et al. Assessment of metals pollution from tailing sites in the North Caucasus Region, Russia // Mine Water and the Environment. 2018. V. 37. Iss. 4. P. 815–824. DOI: 10.1007/s10230-018-0545-x.
6. Alsayed A., Nabawy M.R.A. Stockpile volume estimation in open and confined environments: A review // Drones. 2023. V. 7. Iss. 8. Article 537. DOI: 10.3390/drones7080537.
7. Azad R., Heidary M., Yilmaz K. et al. Loss functions in the era of semantic segmentation: A survey and outlook // <https://arxiv.org/>. arXiv:2312.05391. 2023. 24 p. DOI: 10.48550/arxiv.2312.05391.
8. Chen L.-C., Zhu Y., Papandreou G. et al. Encoder-decoder with atrous separable convolution for semantic image segmentation // Proc. 15<sup>th</sup> European Conf. on Computer Vision (ECCV 2018). Cham: Springer, 2018. P. 833–851. DOI: 10.1007/978-3-030-01234-2\_49.
9. Chen L., Zhang N., Chang J. et al. Indicator element selection and lithological mapping using deep learning methods in the Dahongliutan area, NW China // J. Geochemical Exploration. 2025. V. 268. Article 107611. DOI: 10.1016/j.gexplo.2024.107611.
10. Fonseca A., Marshall M.T., Salama S. Enhanced detection of artisanal small-scale mining with spectral and textural segmentation of Landsat time series // Remote Sensing. 2024. V. 16. Iss. 10. Article 1749. DOI: 10.3390/rs16101749.
11. Gallwey J., Robiati C., Coggan J. et al. A Sentinel-2 based multispectral convolutional neural network for detecting artisanal small-scale mining in Ghana: Applying deep learning to shallow mining // Remote Sensing of Environment. 2020. V. 248. Article 111970. DOI: 10.1016/j.rse.2020.111970.
12. Gao X., Ram S., Rodríguez J.J. Object sieving and morphological closing to reduce false detections in wide-area aerial imagery // <https://arxiv.org/>. arXiv:2010.15260. 2020. 5 p. DOI: 10.48550/arxiv.2010.15260.
13. Jerman T., Pernuš F., Likar B., Špiclin Ž. Beyond Frangi: an improved multiscale vesselness filter // Proc. SPIE. Medical Imaging 2015: Image Processing. 2015. V. 9413. Article 94132A. DOI: 10.1117/12.2081147.
14. Jolliffe I.T., Cadima J. Principal component analysis: a review and recent developments // Philosophical Trans. Royal Soc. A: Mathematical, Physical and Engineering Sciences. 2016. V. 374. Iss. 2065. Article 20150202. DOI: 10.1098/rsta.2015.0202.

15. Kou W., Shen Z., Zhang Y. *et al.* Spatio-temporal analysis of agroforestry systems in hotan using multi-source remote sensing and deep learning // *Smart Agricultural Technology*. 2024. V. 9. Article 100641. DOI: 10.1016/j.atech.2024.100641.
16. Lachaud A., Adam M., Mišković I. Comparative study of random forest and support vector machine algorithms in mineral prospectivity mapping with limited training data // *Minerals*. 2023. V. 13. Iss. 8. Article 1073. DOI: 10.3390/min13081073.
17. Larrea-Gallegos G., Kahhat R., Vázquez-Rowe I., Parodi E. A machine learning approach to understand how accessibility influences alluvial gold mining expansion in the Peruvian Amazon // *Case Studies in Chemical and Environmental Engineering*. 2023. V. 7. Article 100353. DOI: 10.1016/j.cscee.2023.100353.
18. Li C., Feng P., Jiang X. *et al.* Extensive identification of landslide boundaries using remote sensing images and deep learning method // *China Geology*. 2024. V. 7. Iss. 2. P. 277–290. DOI: 10.31035/cg2023148.
19. Lin C.-H., Tang P.-W., Huete A. R. Quantum feature-empowered deep classification for fast mangrove mapping // *IEEE Trans. Geoscience and Remote Sensing*. 2024. V. 63. 13 p. DOI: 10.1109/TGRS.2024.3517459.
20. Liu L., Feng J., Rivard B. *et al.* Mapping alteration using imagery from the Tiangong-1 hyperspectral space-borne system: Example for the Jintanzi gold province, China // *Intern. J. Applied Earth Observation and Geoinformation*. 2018. V. 64. P. 275–286. DOI: 10.1016/j.jag.2017.03.013.
21. Ngom N. M., Mbaye M., Baratoux D. *et al.* Recent expansion of artisanal gold mining along the Bandama River (Côte d'Ivoire) // *Intern. J. Applied Earth Observation and Geoinformation*. 2022. V. 112. Article 102873. DOI: 10.1016/j.jag.2022.102873.
22. Nursamsi I., Sonter L. J., Luskin M. S., Phinn S. Feasibility of multi-spectral and radar data fusion for mapping Artisanal Small-Scale Mining: A case study from Indonesia // *Intern. J. Applied Earth Observation and Geoinformation*. 2024. V. 132. Article 104015. DOI: 10.1016/j.jag.2024.104015.
23. Oktay O., Schlemper J., Le Folgoc L. *et al.* Attention U-Net: Learning where to look for the pancreas // <https://arxiv.org/>. arXiv:1804.03999. 2018. 10 p. DOI: 10.48550/arxiv.1804.03999.
24. Peng D., Liu X., Zhang Y. *et al.* Deep learning change detection techniques for optical remote sensing imagery: Status, perspectives and challenges // *Intern. J. Applied Earth Observation and Geoinformation*. 2025. V. 136. Article 104282. DOI: 10.1016/j.jag.2024.104282.
25. Sahu M., Dash R. Cognitive land cover mapping: A three-layer deep learning architecture for remote sensing data classification // *Environmental Challenges*. 2024. V. 15. Article 100876. DOI: 10.1016/j.envc.2024.100876.
26. Shirmard H., Farahbakhsh E., Müller R. D., Chandra R. A review of machine learning in processing remote sensing data for mineral exploration // *Remote Sensing of Environment*. 2022. V. 268. Article 112750. DOI: 10.1016/j.rse.2021.112750.
27. Shkolnyi D., Magritsky D., Chalov S. Impact of open-cast placer mining on sediment transport across Far Eastern rivers of Russia // *Intern. J. Sediment Research*. 2024. V. 39. Iss. 5. P. 702–713. DOI: 10.1016/j.ijsrc.2024.03.001.
28. Sundararajan M., Taly A., Yan Q. Axiomatic attribution for deep networks // 34<sup>th</sup> Intern. Conf. on Machine Learning. PMLR. 2017. V. 70. P. 3319–3328.
29. Traore M., Wambo J. D. T., Ndepete C. P. *et al.* Lithological and alteration mineral mapping for alluvial gold exploration in the south east of Birao area, Central African Republic using Landsat-8 Operational Land Imager (OLI) data // *J. African Earth Sciences*. 2020. V. 170. Article 103933. DOI: 10.1016/j.jafrearsci.2020.103933.
30. Werner T. T., Mudd G. M., Schipper A. M. *et al.* Global-scale remote sensing of mine areas and analysis of factors explaining their extent // *Global Environmental Change*. 2020. V. 60. Article 102007. DOI: 10.1016/j.gloenvcha.2019.102007.
31. Xie E., Wang W., Yu Z. *et al.* SegFormer: Simple and efficient design for semantic segmentation with transformers // *Advances in Neural Information Processing Systems*. 2021. V. 34. P. 12077–12090.
32. Yao S., Tan K., Wang Y. *et al.* Estimating terrain elevations at 10 m resolution by Integrating random forest machine learning model and ICESat-2, Sentinel-1, and Sentinel-2 satellite remotely sensed data // *Intern. J. Applied Earth Observation and Geoinformation*. 2024. V. 132. Article 104010. DOI: 10.1016/j.jag.2024.104010.
33. Zhou J., Gu X., Gong H. *et al.* Intelligent classification of maize straw types from UAV remote sensing images using DenseNet201 deep transfer learning algorithm // *Ecological Indicators*. 2024. V. 166. Article 112331. DOI: 10.1016/j.ecolind.2024.112331.
34. Zhu Q., Cai Y., Fang Y. *et al.* Samba: Semantic segmentation of remotely sensed images with state space model // *Heliyon*. 2024. V. 10. Iss. 19. Article e38495. DOI: 10.1016/j.heliyon.2024.e38495.

## Detection of dredge tailings dumps in satellite imagery using computer vision and machine learning methods

R. A. Sekrieru, K. S. Tsygulev, S. A. Orlov, S. I. Smagin, T. V. Kozhevnikova

Computing Center FEB RAS, Khabarovsk 680000, Russia

E-mail: roma.sekrieru@gmail.com

The paper presents the results of a study of the potential of automated detection of areas containing dredge tailings from gold mining using satellite data and methods of computer vision and machine learning. The relevance of the study stems from the demand for assessing the reserves of technogenic raw materials in remote and hard-to-reach areas for potential reprocessing. The study uses multispectral imagery from the Sentinel-2 satellites covering the territory of the Far Eastern Federal District of Russia for the period of 2018–2024. Two approaches to solving the problem are considered: a pixel-based approach based on fully connected neural networks and random forest models, and an object-based approach using convolutional and transformer neural networks. An analysis of the informativeness of spectral bands was carried out using gradient-weighted attribution, which made it possible to optimize the input data of the models. To delineate individual tailings within the identified areas, the use of the Frangi filter is proposed that detects linear structures characteristic of dredge tailings.

**Keywords:** remote sensing of the Earth, gold mining, mine tailings, dredging method, computer vision, machine learning

Accepted: 11.06.2026

DOI: 10.21046/2070-7401-2026-23-4-89-102

## References

1. Galchenko Yu. P., Ozaryan Yu. A., Kozhevnikova T. V., Okladnikov V. E., Identification of mining waste disposal sites using remote sensing data, *Physical and technical problems of mineral development*, 2024, Iss. 4, pp. 173–179 (in Russian), DOI: 10.15372/FTPRI20240415.
2. Kalashnik A. I., Maskimov D. A., Kalashnik N. A. et al. *Mnogourovnevnye kompleksnye issledovaniya i monitoring khvostokhranilishch gornodobyvayushchikh predpriyatii severo-zapadnoi chasti Rossiiskogo sektora Arktiki* (Multi-level integrated research and monitoring of tailings storage facilities of mining enterprises in the northwestern part of the Russian Arctic), Apatity: FRC KSC RAS, 2022, 250 p. (in Russian), DOI: 10.37614/978.5.91137.465.5.
3. Litvintsev V. I., Ysikov V. I., Ozaryan Yu. A., Alekseev V. S., Remote sensing of the Earth as a part of research of assessing the volume of technogenic raw and the environmental situation during the exploitation of placers, *Georesources*, 2021, V. 23, No. 4, pp. 116–123 (in Russian), DOI: 10.18599/grs.2021.4.13.
4. Churkin O. E., Gilyarova A. A., Mining wastes management as an investment direction for the development of the Kola Peninsula mining industry, *J. Economics, Entrepreneurship and Law*, 2020, V. 10, No. 3, pp. 905–916 (in Russian), DOI: 10.18334/epp.10.3.100742.
5. Abu Qdais H., Begday I. V., Katorgin I. Yu. et al., Assessment of metals pollution from tailing sites in the North Caucasus Region, Russia, *Mine Water and the Environment*, 2018, V. 37, Iss. 4, pp. 815–824, DOI: 10.1007/s10230-018-0545-x.
6. Alsayed A., Nabawy M. R. A., Stockpile volume estimation in open and confined environments: A review, *Drones*, 2023, V. 7, Iss. 8, Article 537, DOI: 10.3390/drones7080537.
7. Azad R., Heidary M., Yilmaz K. et al., Loss functions in the era of semantic segmentation: A survey and outlook, <https://arxiv.org/>, arXiv:2312.05391, 2023, 24 p., DOI: 10.48550/arxiv.2312.05391.
8. Chen L.-C., Zhu Y., Papandreou G. et al., Encoder-decoder with atrous separable convolution for semantic image segmentation, *Proc. 15<sup>th</sup> European Conf. on Computer Vision (ECCV 2018)*, Cham: Springer, 2018, pp. 833–851, DOI: 10.1007/978-3-030-01234-2\_49.
9. Chen L., Zhang N., Chang J. et al., Indicator element selection and lithological mapping using deep learning methods in the Dahongliutan area, NW China, *J. Geochemical Exploration*, 2025, V. 268, Article 107611, DOI: 10.1016/j.gexplo.2024.107611.
10. Fonseca A., Marshall M. T., Salama S., Enhanced detection of artisanal small-scale mining with spectral and textural segmentation of Landsat time series, *Remote Sensing*, 2024, V. 16, Iss. 10, Article 1749, DOI: 10.3390/rs16101749.

11. Gallwey J., Robiati C., Coggan J. et al., A Sentinel-2 based multispectral convolutional neural network for detecting artisanal small-scale mining in Ghana: Applying deep learning to shallow mining, *Remote Sensing of Environment*, 2020, V. 248, Article 111970, DOI: 10.1016/j.rse.2020.111970.
12. Gao X., Ram S., Rodríguez J.J., Object sieving and morphological closing to reduce false detections in wide-area aerial imagery, <https://arxiv.org/>, arXiv:2010.15260, 2020, 5 p., DOI: 10.48550/arxiv.2010.15260.
13. Jerman T., Pernuš F., Likar B., Špiclin Z., Beyond Frangi: an improved multiscale vesselness filter, *Proc. SPIE. Medical Imaging 2015: Image Processing*, 2015, V. 9413, Article 94132A, DOI: 10.1117/12.2081147.
14. Jolliffe I.T., Cadima J., Principal component analysis: a review and recent developments, *Philosophical Trans. Royal Soc. A: Mathematical, Physical and Engineering Sciences*, 2016, V. 374, Iss. 2065, Article 20150202, DOI: 10.1098/rsta.2015.0202.
15. Kou W., Shen Z., Zhang Y. et al., Spatio-temporal analysis of agroforestry systems in hotan using multi-source remote sensing and deep learning, *Smart Agricultural Technology*, 2024, V. 9, Article 100641, DOI: 10.1016/j.atech.2024.100641.
16. Lachaud A., Adam M., Mišković I., Comparative study of random forest and support vector machine algorithms in mineral prospectivity mapping with limited training data, *Minerals*, 2023, V. 13, Iss. 8, Article 1073, DOI: 10.3390/min13081073.
17. Larrea-Gallegos G., Kahhat R., Vázquez-Rowe I., Parodi E., A machine learning approach to understand how accessibility influences alluvial gold mining expansion in the Peruvian Amazon, *Case Studies in Chemical and Environmental Engineering*, 2023, V. 7, Article 100353, DOI: 10.1016/j.cscee.2023.100353.
18. Li C., Feng P., Jiang X. et al., Extensive identification of landslide boundaries using remote sensing images and deep learning method, *China Geology*, 2024, V. 7, Iss. 2, pp. 277–290, DOI: 10.31035/cg2023148.
19. Lin C.-H., Tang P.-W., Huete A. R., Quantum feature-empowered deep classification for fast mangrove mapping, *IEEE Trans. Geoscience and Remote Sensing*, 2024, V. 63, 13 p., DOI: 10.1109/TGRS.2024.3517459.
20. Liu L., Feng J., Rivard B. et al., Mapping alteration using imagery from the Tiangong-1 hyperspectral spaceborne system: Example for the Jintanzi gold province, China, *Intern. J. Applied Earth Observation and Geoinformation*, 2018, V. 64, pp. 275–286, DOI: 10.1016/j.jag.2017.03.013.
21. Ngom N. M., Mbaye M., Baratoux D. et al., Recent expansion of artisanal gold mining along the Bandama River (Côte d'Ivoire), *Intern. J. Applied Earth Observation and Geoinformation*, 2022, V. 112, Article 102873, DOI: 10.1016/j.jag.2022.102873.
22. Nursamsi I., Sonter L.J., Luskin M.S., Phinn S., Feasibility of multi-spectral and radar data fusion for mapping Artisanal Small-Scale Mining: A case study from Indonesia, *Intern. J. Applied Earth Observation and Geoinformation*, 2024, V. 132, Article 104015, DOI: 10.1016/j.jag.2024.104015.
23. Oktay O., Schlemper J., Le Folgoc L. et al., Attention U-Net: Learning where to look for the pancreas, <https://arxiv.org/>, arXiv:1804.03999, 2018, 10 p., DOI: 10.48550/arxiv.1804.03999.
24. Peng D., Liu X., Zhang Y. et al., Deep learning change detection techniques for optical remote sensing imagery: Status, perspectives and challenges, *Intern. J. Applied Earth Observation and Geoinformation*, 2025, V. 136, Article 104282, DOI: 10.1016/j.jag.2024.104282.
25. Sahu M., Dash R., Cognitive land cover mapping: a three-layer deep learning architecture for remote sensing data classification, *Environmental Challenges*, 2024, V. 15, Article 100876, DOI: 10.1016/j.envc.2024.100876.
26. Shirmard H., Farahbakhsh E., Müller R. D., Chandra R., A review of machine learning in processing remote sensing data for mineral exploration, *Remote Sensing of Environment*, 2022, V. 268, Article 112750, DOI: 10.1016/j.rse.2021.112750.
27. Shkolnyi D., Magritsky D., Chalov S., Impact of open-cast placer mining on sediment transport across Far Eastern rivers of Russia, *Intern. J. Sediment Research*, 2024, V. 39, Iss. 5, pp. 702–713, DOI: 10.1016/j.ijsrc.2024.03.001.
28. Sundararajan M., Taly A., Yan Q., Axiomatic attribution for deep networks, *34<sup>th</sup> Intern. Conf. on Machine Learning*, PMLR, 2017, V. 70, pp. 3319–3328.
29. Traore M., Wambo J.D.T., Ndepete C.P. et al., Lithological and alteration mineral mapping for alluvial gold exploration in the south east of Birao area, Central African Republic using Landsat-8 Operational Land Imager (OLI) data, *J. African Earth Sciences*, 2020, V. 170, Article 103933, DOI: 10.1016/j.jafrearsci.2020.103933.
30. Werner T.T., Mudd G.M., Schipper A.M. et al., Global-scale remote sensing of mine areas and analysis of factors explaining their extent, *Global Environmental Change*, 2020, V. 60, Article 102007, DOI: 10.1016/j.gloenvcha.2019.102007.
31. Xie E., Wang W., Yu Z. et al., SegFormer: Simple and efficient design for semantic segmentation with transformers, *Advances in Neural Information Processing Systems*, 2021, V. 34, pp. 12077–12090.
32. Yao S., Tan K., Wang Y. et al., Estimating terrain elevations at 10 m resolution by Integrating random forest machine learning model and ICESat-2, Sentinel-1, and Sentinel-2 satellite remotely sensed data, *Intern. J. Applied Earth Observation and Geoinformation*, 2024, V. 132, Article 104010, DOI: 10.1016/j.jag.2024.104010.

33. Zhou J., Gu X., Gong H. et al., Intelligent classification of maize straw types from UAV remote sensing images using DenseNet201 deep transfer learning algorithm, *Ecological Indicators*, 2024, V. 166, Article 112331, DOI: 10.1016/j.ecolind.2024.112331.
34. Zhu Q., Cai Y., Fang Y. et al., Samba: Semantic segmentation of remotely sensed images with state space model, *Heliyon*, 2024, V. 10, Iss. 19, Article e38495, DOI: 10.1016/j.heliyon.2024.e38495.