

УДК 004.8:504.5:528.8

DOI: 10.46698/VNC.2026.86.51.001

Оригинальная статья

Интеллектуальная классификация нефтезагрязненных территорий по данным геоэкологического мониторинга

В.А. Красиков¹, Г.В. Кораблева², В.В. Пчелкин²,
И.А. Вахрушева², Н.А. Штырхунова³

¹ Московский государственный технический университет им. Н.Э. Баумана,
Россия, 105005, г. Москва, ул. 2-я Бауманская, 5,
e-mail: vitkras@inbox.ru;

² Российский государственный аграрный университет – МСХА
им. К.А. Тимирязева, Россия, 127434, г. Москва, ул. Тимирязевская, 49,
e-mail: korableva@rgau-msha.ru, 9766793@mail.ru, vakhrusheva@rgau-msha.ru;

³ Государственный морской университет им. адмирала Ф.Ф. Ушакова,
Россия, 353918, г. Новороссийск, пр. Ленина, 93,
e-mail: shtnat33@mail.ru

Статья поступила: 15.07.2026, доработана: 21.08.2026, принята к публикации: ...2026

Резюме: Актуальность работы. Нефтяное загрязнение почвенного покрова имеет сложный пространственный характер и может долго сохраняться на промышленных и прилегающих территориях. Его оценка не должна ограничиваться только содержанием нефтепродуктов, поскольку состояние участка зависит от рельефа, влажности, гранулометрического состава, растительности, поверхностного стока и положения относительно источников загрязнения. **Цель исследования.** Разработать подход к интеллектуальной классификации нефтезагрязненных территорий на основе комплексной обработки данных геоэкологического мониторинга, лабораторного анализа почв, дистанционного зондирования и ГИС-моделирования. **Методы исследования.** Использованы результаты полевого обследования, лабораторные определения нефтепродуктов в почвенных пробах, материалы дистанционного зондирования, цифровая модель поверхности и ГИС-показатели рельефа, влажности, растительного покрова, расстояния до источников загрязнения и близости к зонам стока. Для классификации применялись k-nearest neighbors, Support Vector Machine, Gradient Boosting и Random Forest. Эффективность оценивалась по точности, F1-мере, устойчивости разделения классов и интерпретируемости факторов. **Результаты.** Наиболее значимыми признаками оказались содержание нефтепродуктов, влажность почвы, NDVI, доля глинистой фракции, расстояние до источника, уклон поверхности и близость к элементам стока. Лучшие результаты получены для Random Forest: точность 0,84–0,87, F1-мера 0,78–0,90. Выделены фоновые, слабозагрязненные, умеренно загрязненные, сильно и очень сильно загрязненные участки. Последние занимают около 8–12% и 3–5% территории, но формируют основной экологический риск.

Ключевые слова: нефтезагрязненные территории, геоэкологический мониторинг, искусственный интеллект, машинное обучение, Random Forest, дистанционное зондирование, NDVI, геоинформационный анализ.

Для цитирования: Красиков В.А., Кораблева Г.В., Пчелкин В.В., Вахрушева И.А., Штырхунова Н.А. Интеллектуальная классификация нефтезагрязненных территорий по данным геоэкологического мониторинга. *Геология и геофизика Юга России*. 2026. 16(3): DOI: 10.46698/VNC.2026.86.51.001

DOI: 10.46698/VNC.2026.86.51.001

Original paper

Intelligent classification of oil-contaminated areas based on geoeological monitoring data

V.A. Krasikov¹, G.V. Korableva², V.V. Pchelkin²,
I.A. Vakhrusheva², N.A. Shtyrkhunova³

¹ Bauman Moscow State Technical University, 5, 2nd Baumanskaya Str., Moscow 105005, Russian Federation, e-mail: vitkras@inbox.ru;

² Russian State Agrarian University – Moscow Timiryazev Agricultural Academy, 49 Timiryazevskaya Str., Moscow 127434, Russian Federation, e-mail: korableva@rgau-msha.ru, 9766793@mail.ru, vakhrusheva@rgau-msha.ru;

³ Admiral F.F. Ushakov State Maritime University, 93 Lenin Ave., Novorossiysk 353918, Russian Federation, e-mail: shtnat33@mail.ru

Received: 15.07.2026, revised: 21.08.2026, accepted:2026

Abstract: Relevance. Oil pollution of the soil cover has a complex spatial pattern and may persist for a long time in industrial and adjacent areas. Its assessment should not be limited only to petroleum hydrocarbon content, since site conditions also depend on terrain, moisture, granulometric composition, vegetation, surface runoff, and position relative to pollution sources. **Aim of the study.** The study aims to develop an approach for intelligent classification of oil-contaminated areas based on integrated processing of geoeological monitoring data, laboratory soil analysis, remote sensing, and GIS modeling. **Research methods.** Field survey results, laboratory measurements of petroleum hydrocarbons in soil samples, remote sensing materials, a digital surface model, and GIS indicators of terrain, moisture, vegetation cover, distance to pollution sources, and proximity to runoff zones were used. The k-nearest neighbors, Support Vector Machine, Gradient Boosting, and Random Forest algorithms were applied for classification. Model performance was evaluated by accuracy, F1-score, stability of class separation, and factor interpretability. **Results.** The most significant indicators were petroleum hydrocarbon content, soil moisture, NDVI, clay fraction, distance to the source, surface slope, and proximity to runoff elements. Random Forest provided the best results, with an accuracy of 0.84–0.87 and F1-score of 0.78–0.90. Background, slightly contaminated, moderately contaminated, heavily contaminated, and extremely contaminated areas were identified. The last two classes occupy about 8–12% and 3–5% of the territory but form the main environmental risk.

Keywords: oil-contaminated areas, geoeological monitoring, artificial intelligence, machine learning, Random Forest, remote sensing, NDVI, geoinformation analysis.

For citation: Krasikov V.A., Korableva G.V., Pchelkin V.V., Vakhrusheva I.A., Shtyrkhunova N.A. Intelligent classification of oil-contaminated areas based on geoeological monitoring data. *Geologiya i Geofizika Yuga Rossii = Geology and Geophysics of Russian South*. (in Russ.). 2026. 16(3): DOI: 10.46698/VNC.2026.86.51.001

Введение

Нефтяное загрязнение промышленных и прилегающих земель обычно сохраняется длительное время, особенно в районах добычи, перекачки, хранения, аварийных сливов и переработки нефти [Shukla et al., 2025]. При проникновении нефтепродуктов в верхние горизонты почвы меняются ее плотность, влажность, кислотность, воздухообмен, фильтрационная способность и содержание органического вещества [Fomina et al., 2016]. Внешние признаки постепенно сглаживаются: растительность частично

восстанавливается, запах исчезает, но остаточные углеводороды могут сохраняться в микропонижениях, суглинках, канавах и слабодренированных местах [Hao et al., 2025].

Поэтому геоэкологическое состояние нельзя определять только визуально или по отдельным лабораторным концентрациям. Даже близкие точки могут отличаться по содержанию нефтепродуктов в 2–3 раза, а участки с похожими значениями иметь разный риск из-за рельефа, влажности и условий стока. Современный мониторинг должен сочетать полевые обследования, отбор проб, лабораторный анализ, ГИС-обработку и учет природных условий [Wijaya et al., 2024]. Нефтепродукты распределяются по микрорельефу, колеям, ложбинам стока и участкам с разной проницаемостью грунта [Osranova et al., 2025].

Сопоставление только лабораторных концентраций является слишком грубым: оно показывает превышения, но плохо объясняет удержание и миграцию загрязнения [Азаров и др., 2024]. Поэтому более обоснованно выделять не только «чистые» и «грязные» участки, но и несколько классов состояния: фоновое, слабое, умеренное, сильное и очень сильное загрязнение.

Сложность анализа усиливается разнородностью данных: лабораторные показатели, данные дистанционного зондирования, геоморфология, растительность и гидрографическая сеть описывают один природно-техногенный процесс, но часто рассматриваются отдельно [Banace et al., 2024]. Это повышает зависимость оценки от методики и опыта исследователя [Yelemessov et al., 2026]. Методы искусственного интеллекта позволяют объединять такие данные и выявлять связи, плохо фиксируемые обычной статистикой [Barathkumar, Devi, 2025]. ИИ уже применяется для классификации нарушенных земель, анализа растительности, прогноза техногенного риска и обработки данных мониторинга [Маслов, Орлов, 2026]. Для нефтезагрязненных территорий это особенно важно, поскольку один уровень загрязнения имеет разное экологическое значение в песчаных, суглинистых и заболоченных почвах [Karshyga et al., 2022; Ключев и др., 2024], а классификация по одному показателю недостаточно корректна [Нурпеисова и др., 2023]. Алгоритмы машинного обучения позволяют учитывать химические, почвенные, ландшафтные и дистанционные признаки [Garcia et al., 2025]. Random Forest, Gradient Boosting, SVM и нейросетевые модели могут не только разделять территорию на классы, но и определять факторы, влияющие на формирование загрязнения [Татаринцев и др., 2026]. Это важно для понимания причин повышенной уязвимости отдельных участков [Затонский и др., 2025]. Несмотря на развитие цифровых методов, классификация нефтезагрязненных территорий как единой геоэкологической задачи остается недостаточно разработанной [Sumi, Chandrasekar, 2024]. Необходимо объединять лабораторные, дистанционные и пространственные данные в воспроизводимую систему оценки [Толеубекова и др., 2025; Didmanidze et al., 2025].

Цель работы – разработать подход к классификации нефтезагрязненных территорий по данным геоэкологического мониторинга с использованием методов искусственного интеллекта, включая подготовку данных, пространственную привязку, формирование классов загрязнения и сравнение алгоритмов классификации [Kulikova et al., 2024].

Методы и материалы

В качестве исходных материалов использовались данные геоэкологического обследования нефтезагрязненной территории, связанной с длительной эксплуатацией объектов хранения и транспортировки нефтепродуктов. Участок рассматривался как природно-техногенная система, где загрязнение формируется не только прямым поступлением нефтепродуктов, но и их перераспределением по микрорельефу, поверхностному стоку и зонам с разной водопроницаемостью грунтов.

Полевой этап включал основную и уточняющую сетки наблюдений. Сначала при-

меняли шаг 50×50 м, затем в подозрительных зонах сгущали сеть до 25, 20, 15 и 10 м. Учитывались понижения, переувлажненные пятна, старые насыпи, технологические проезды, нарушенная растительность и следы загрязнения. Координаты точек фиксировались GNSS-приемником с точностью около 0,5–1,0 м. Пробы отбирались из слоя 0–20 см, а при признаках вертикальной миграции дополнительно из горизонта 20–40 см.

Содержание нефтепродуктов определяли после экстракции органическим растворителем методом ИК-спектрометрии; для части проб уточняли фракционный состав газовой хроматографией. Дополнительно определяли pH, влажность, органическое вещество, гранулометрический состав и, при необходимости, содержание тяжелых металлов.

Для пространственного анализа использовались снимки Sentinel-2, материалы БПЛА, ортофотоплан и цифровая модель поверхности. По ним выделяли микропонижения, техногенные валы, колеи, старые дороги, нарушенную растительность и зоны возможного вторичного накопления загрязнений. В QGIS рассчитывали NDVI и SAVI; эти показатели рассматривались вместе с влажностью, уклоном, расстоянием до источника и лабораторными концентрациями.

Лабораторные, полевые и пространственные данные сводились в единую таблицу признаков: содержание нефтепродуктов, влажность, pH, органическое вещество, песчаная и глинистая фракции, NDVI, SAVI, высота, уклон, расстояние до источника загрязнения и до элементов стока. Каждой точке присваивался один из пяти классов: фоновое состояние, слабое, умеренное, сильное или очень сильное загрязнение. Класс определялся не только концентрацией нефтепродуктов, но и природными условиями участка.

Моделирование выполнялось в Python с использованием pandas, numpy, scikit-learn, matplotlib и geopandas. Перед обучением проверяли пропуски, выбросы, нормализовали признаки и анализировали корреляции. Для классификации применялись Random Forest, Gradient Boosting, Support Vector Machine и k-nearest neighbors. Выборка делилась на обучающую и тестовую части в соотношении 70:30, качество оценивалось по accuracy, F1-мере, полноте и матрице ошибок. Для лучшей модели дополнительно рассчитывали значимость признаков, чтобы получить не только формальную классификацию, но и объяснимую геоэкологическую схему для мониторинга и рекультивации.

Результаты и обсуждение

По итогам геоэкологического обследования был собран разнородный массив данных о состоянии почвенного покрова: химические, почвенные, рельефные, дистанционные и визуально-полевые признаки. Главным параметром оставалось содержание нефтепродуктов, однако его распределение оказалось крайне неравномерным. Повышенные значения фиксировались не только рядом с источником, но и на удалении 80–120 м, что связано с переносом по микрорельефу, задержкой в понижениях, канавах, колеях и тяжелых почвах.

Концентрации нефтепродуктов изменялись от фоновых 80–150 мг/кг до сильного и очень сильного загрязнения выше 2000–3000 мг/кг. Низкие значения чаще совпадали с плотным растительным покровом, NDVI 0,50–0,65 и хорошим дренажем. Повышенные концентрации были характерны для понижений глубиной 0,2–0,5 м, техногенных канав, старых проездов и участков с разреженной растительностью. При этом визуально восстановленные площадки иногда сохраняли загрязнение в слоях 0–20 и 20–40 см.

Сопоставление лабораторных данных с цифровой моделью поверхности показало связь загрязнения с зонами слабого стока: малыми уклонами 1–3°, локальными понижениями, влажностью выше 22–30% и повышенной долей пылевато-глинистой фракции 25–40%. Дистанционные индексы также были полезны: на фоновых участках NDVI составлял 0,52–0,68, а в зонах сильного загрязнения снижался до 0,25–0,38. Однако NDVI и SAVI нельзя использовать изолированно, так как на них влияют уплотнение, переувлажнение, механическое нарушение, дороги и тень.

Для классификации точки группировали по совокупности признаков. Первично учитывали концентрации нефтепродуктов, затем уточняли классы по влажности, уклону, NDVI, гранулометрическому составу, положению относительно источника и расстоянию до элементов стока. В итоге выделены пять групп: фоновое состояние, слабое, умеренное, сильное и очень сильное загрязнение. Такая схема лучше отражает возможность накопления, выноса или закрепления нефтепродуктов в почвенном профиле.

После подготовки выборки были построены модели машинного обучения. K-nearest neighbors лучше разделял крайние классы, но хуже работал с переходными зонами. Support Vector Machine был стабильнее, но чувствителен к нормализации и настройкам ядра. Лучшие результаты дали ансамблевые методы – Random Forest и Gradient Boosting. Для Random Forest общая точность на тестовой выборке составила 0,84–0,87, F1-мера – 0,78–0,90. Модель наиболее уверенно распознавала фоновые и сильно загрязненные участки, а ошибки чаще возникали между соседними категориями. Gradient Boosting показал сопоставимое качество, но сильнее зависел от состава выборки, поэтому для интерпретации была выбрана модель Random Forest (табл. 1).

Таблица 1 / Table 1

**Результаты классификации нефтезагрязненных территорий различными
алгоритмами машинного обучения /
Results of classification of oil-contaminated areas using various
machine learning algorithms**

Метод классификации / Classification method	Общая точность / Overall accuracy	Precision	Recall	F1-мера	Основные особенности результата / Main features of the result
k-nearest neighbors	0.73	0.71	0.69	0.70	Хорошо выделяет фоновые и сильно загрязненные участки, но хуже разделяет слабое и умеренное загрязнение / Clearly identifies background and heavily contaminated areas, but less effectively separates weak and moderate contamination
Support Vector Machine	0.79	0.78	0.76	0.77	Дает более устойчивое разделение классов, но чувствителен к нормализации признаков и выбору ядра / Provides more stable class separation, but is sensitive to feature normalization and kernel selection
Gradient Boosting	0.85	0.84	0.83	0.83	Показывает высокую точность, но сильнее зависит от состава обучающей выборки / Shows high accuracy, but depends more strongly on the composition of the training sample
Random Forest	0.87	0.86	0.85	0.85	Обеспечивает наиболее устойчивую классификацию и позволяет оценивать значимость отдельных признаков / Provides the most stable classification and allows the importance of individual features to be assessed

Матрица ошибок показала важную практическую особенность: модель почти не относила сильно загрязненные участки к фоновым или слабозагрязненным. Это хороший результат, потому что именно такая ошибка была бы наиболее опасной при планировании мониторинга или рекультивации. Основные неточности имели вид смещения на 1 соседний класс: умеренное загрязнение могло быть принято за слабое или, наоборот, за сильное. Но в фон такие точки почти не уходили. Например, участок с концентрацией 1200–1500 мг/кг, влажностью 24–29%, NDVI 0,33–0,41 и уклоном около 2° мог получить соседнюю оценку, если его признаки находились на границе 2 категорий. Это

показывает, что модель в целом правильно схватывает структуру загрязнения, а неопределенность остается там, где она реально есть в природе. Переходные зоны редко бывают однозначными, потому что в них одновременно наблюдаются остаточные нефтепродукты, частичное восстановление травостоя, разная плотность почвы, и неодинаковая водопроницаемость.

Оценка значимости признаков для Random Forest подтвердила, что главным фактором всё равно остается содержание нефтепродуктов в почве. Но оно не объясняет картину полностью.




Рис. 1. Значимость признаков при классификации нефтезагрязненных территорий методом Random Forest

Fig. 1. Significance of features when classifying oil-contaminated areas using the Random Forest method

Наибольший вклад в разделение классов вносит содержание нефтепродуктов, однако важны также влажность, NDVI, гранулометрический состав и морфология поверхности (рис. 1). Вероятность отнесения участка к неблагоприятному классу возрастала при влажности выше 25–30%, доле глинистых частиц 25–40%, уклоне менее 2–3° и NDVI ниже 0,35. Это показывает, что нефтяное загрязнение является не только химическим показателем, но и пространственно-ландшафтным процессом.

Карта классификации показала, что зоны сильного и очень сильного загрязнения занимают ограниченную площадь, примерно 8–12% и 3–5% обследованной территории, но формируют основной экологический риск. Они располагались около источников нефтепродуктов на расстоянии 10–40 м, а также в местах вторичного накопления: канавах, микропонижениях, старых проездах и участках с ослабленным растительным покровом. Вокруг них формировалась переходная зона умеренного загрязнения, состояние которой может меняться в зависимости от дренажа, повторных поступлений и влажности почвы.

Сравнение машинной классификации с экспертной оценкой показало, что алгоритмы ИИ детальнее отражают внутреннюю неоднородность территории. Точки с близкими концентрациями могли получать разную оценку риска из-за различий во влажности, NDVI, уклоне, дренированности и близости к путям поверхностного переноса. Поэтому модель не заменяет лабораторный анализ, а связывает отдельные наблюдения в более цельную пространственную картину.

Материалы БПЛА позволили уточнить положение техногенных форм, локальных понижений, старых дорог и участков с разреженной растительностью. Спутниковые снимки Sentinel-2 давали общий фон, а беспилотная съемка уточняла малые пятна загрязнения площадью 50–200 м².

Полученные результаты можно использовать для корректировки сети мониторинга: в фоновых зонах сохранять шаг 50×50 м или увеличивать его до 75×75 м, а в подозрительных местах сгущать до 10–25 м. Это может снизить объем работ на 15–30% без потери качества оценки. При этом необходимо учитывать ограничения: зависимость результата от обучающей выборки, сезонности и глубины отбора проб. Если анализируется только слой 0–20 см, на песчаных участках возможно недоучитывание загрязнения в горизонте 20–40 см и глубже (табл. 2). Наиболее устойчивые результаты среди рассмотренных методов показал Random Forest.

Таблица 2 / Table 2

Геоэкологическая характеристика выделенных классов нефтезагрязненных территорий /
Geocological characteristics of the identified classes of oil-contaminated areas

Класс геоэкологического состояния / Class of geocological condition	Содержание нефтепродуктов, мг/кг / Petroleum product content, mg/kg	Характерные признаки территории / Characteristic features of the area	Геоэкологическая интерпретация / Geocological interpretation	Рекомендуемые действия / Recommended actions
Фоновое состояние / Background condition	до 100 / up to 100	Сохраненный растительный покров, нормальные значения NDVI, отсутствие визуальных следов загрязнения / Preserved vegetation cover, normal NDVI values, absence of visible signs of contamination	Территория не имеет выраженных признаков нефтяного воздействия / The area has no pronounced signs of petroleum impact	Периодический контроль по стандартной сети мониторинга / Periodic control using the standard monitoring network
Слабое загрязнение / Weak contamination	100–500	Незначительное снижение NDVI, локальные нарушения почвенного покрова, слабая техногенная нагрузка / Slight decrease in NDVI, local disturbances of the soil cover, weak technogenic load	Начальная или остаточная форма загрязнения без выраженной деградации почв / Initial or residual form of contamination without pronounced soil degradation	Повторный контроль, уточнение источника поступления загрязнения / Repeated monitoring and clarification of the contamination source
Умеренное загрязнение / Moderate contamination	500–1000	Угнетение растительности, повышенная влажность, связь с микропонижениями и зонами стока / Vegetation suppression, increased moisture, association with microdepressions and runoff zones	Переходное состояние, при котором возможно как восстановление, так и усиление загрязнения / Transitional condition in which both recovery and intensification of contamination are possible	Учащенный мониторинг, локальная рекультивация при сохранении загрязнения / More frequent monitoring and local remediation if contamination persists
Сильное загрязнение / Strong contamination	1000–5000	Низкие значения NDVI, пятнистое распределение растительности, повышенное содержание нефтепродуктов / Low NDVI values, patchy vegetation distribution, increased petroleum product content	Устойчивая зона техногенного воздействия с нарушением почвенных функций / Stable zone of technogenic impact with impaired soil functions	Рекультивация, удаление или обработка загрязненного грунта / Remediation, removal, or treatment of contaminated soil
Очень сильное загрязнение / Very strong contamination	более 5000 / more than 5000	Резкое угнетение или отсутствие растительности, выраженные следы нефтепродуктов, локальные зоны накопления / Severe suppression or absence of vegetation, pronounced traces of petroleum products, local accumulation zones	Максимально неблагоприятные участки, формирующие основной экологический риск / The most unfavorable areas forming the main environmental risk	Приоритетная / Priority




Рис. 2. Пространственное распределение классов нефтяного загрязнения по результатам геоэкологической классификации /

Fig. 2. Spatial distribution of oil pollution classes based on the results of geoeological classification

На рисунке 2 показана схема пространственного распределения классов нефтяного загрязнения, полученная по данным геоэкологического мониторинга и модели классификации. Наиболее загрязненные зоны тяготеют к источнику поступления нефтепродуктов и локальным понижениям, связанным с направлением поверхностного стока.

Практическое значение такого подхода состоит в том, что он помогает не просто разделить территорию на 5 классов загрязнения, а понять, почему одни участки являются более опасными, чем другие. Модель учитывает концентрацию нефтепродуктов, влажность, гранулометрический состав, NDVI, уклон поверхности, расстояние до источника и близость к элементам стока, поэтому итоговая карта получается более похожей на реальную природно-техногенную ситуацию. Это важно для выбора зон рекультивации, уточнения мониторинговой сети и обоснования природоохранных решений. При этом связь с традиционной геоэкологической оценкой сохраняется: лабораторные пробы остаются основой, а методы машинного обучения делают обработку более формализованной, воспроизводимой и удобной для анализа территорий, где загрязнение сохраняется долго, распределяется пятнами и не всегда хорошо видно по внешним признакам.

Выводы

На основании выполненного исследования, где рассматривалась классификация нефтезагрязненных земель по данным геоэкологического мониторинга и с применением методов искусственного интеллекта, можно сформулировать несколько основных выводов. Они связаны не только с работой моделей, но и с самим характером распределения загрязнения на участке.

Показано, что нефтяное загрязнение почвенного покрова имеет явно выраженный мозаичный характер, и описывать его только по отдельным лабораторным концентрациям нельзя. Даже при близких значениях концентрации нефтепродуктов, например 850, 970 или 1100 мг/кг, фактическое состояние участков может различаться довольно заметно. Это связано с влажностью почвы, долей глинистой фракции, уклоном поверхности, состоянием растительности, расстоянием до источника и положением точки от-

носителем зон поверхностного стока. Поэтому нефтезагрязненная территория в данной работе рассматривалась не как простая сумма загрязненных проб, а как природно-техногенная система, где углеводородные компоненты перемещаются, частично задерживаются, а иногда уходят ниже по профилю. На участках с уклоном $1-3^\circ$, влажностью 25–35% и ослабленным растительным покровом вероятность накопления была выше. А на более дренированных фрагментах, при уклоне $4-6^\circ$ и NDVI около 0,50–0,65, картина выглядела уже другой, даже если исходная концентрация была похожей.

Установлено, что объединение лабораторных, почвенных, дистанционных и геоморфологических данных заметно повышает содержательность геоэкологической оценки. Наиболее значимыми признаками оказались содержание нефтепродуктов, влажность, NDVI, доля глинистой фракции, расстояние до источника загрязнения, уклон поверхности и близость к элементам поверхностного стока. Это важно. Полученные результаты показывают, что устойчивые зоны загрязнения формируются не только там, где произошло поступление нефтепродуктов, но и там, где есть условия для их удержания: локальные понижения глубиной 0,2–0,6 м, слабый сток, тяжелый гранулометрический состав, переувлажнение, разреженная растительность. В таких местах даже через 1–2 сезона могут сохраняться остаточные концентрации, а визуально участок уже иногда выглядит почти восстановленным. Поэтому учет рельефа и почвенно-растительного состояния оказался не дополнительным, а фактически обязательным элементом анализа.

Сравнение алгоритмов машинного обучения показало, что наиболее стабильные результаты были получены при использовании ансамблевых методов. В первую очередь это Random Forest и Gradient Boosting. Модель Random Forest дала лучшее сочетание точности, устойчивости и понятной интерпретации, что для геоэкологических задач особенно важно. По тестовой выборке ее общая точность находилась примерно в пределах 0,84–0,87, а F1-мера по основным классам составляла около 0,78–0,90. В отличие от более простых подходов, модель позволила не только разделить территорию на 5 классов, то есть фоновое состояние, слабое, умеренное, сильное и очень сильное загрязнение, но и оценить вклад отдельных факторов. Основные ошибки возникали между соседними категориями, например между слабым и умеренным или между умеренным и сильным загрязнением. Это в целом нормально, потому что природная среда редко имеет резкую границу, и переходная зона шириной 10–30 м может иметь смешанные признаки.

Карта классификации показала, что зоны сильного и очень сильного загрязнения занимают сравнительно небольшую часть территории. Условно их площадь может составлять около 8–12% и 3–5% от обследованного участка, но именно они формируют основной экологический риск.

Эти неблагоприятные фрагменты связаны как с близостью к источникам поступления нефтепродуктов, обычно в пределах 10–40 м, так и с зонами вторичного накопления, куда загрязняющие вещества переносились поверхностным стоком. Умеренно загрязненные участки образуют вокруг них переходную область, и ее состояние может меняться во времени. При отсутствии новых поступлений, нормальном дренаже и рекультивации такая зона может постепенно перейти в слабозагрязненный класс. Но при повторном загрязнении, застое влаги или нарушении поверхностного стока, наоборот, возможно расширение неблагоприятных пятен. Поэтому эти территории нельзя оставлять без наблюдения, даже если концентрации там не максимальные.

Таким образом, применение методов искусственного интеллекта при обработке данных геоэкологического мониторинга позволяет сделать оценку нефтезагрязненных земель более формализованной, воспроизводимой и пространственно обоснованной. Предложенный подход не заменяет полевые маршруты, отбор проб и лабораторные определения, а связывает их в единую систему анализа. Он помогает уточнять сеть

мониторинга, выбирать точки дополнительного контроля, выделять приоритетные участки рекультивации и обосновывать природоохранные решения. Наиболее перспективным продолжением работы является расширение обучающей выборки хотя бы до 150–200 точек, проведение повторных съемок в разные сезоны (например, весной, летом и осенью), а также включение данных глубинного отбора проб из горизонтов 20–40 см и 40–60 см. Это позволит точнее оценить вертикальную миграцию нефтепродуктов и лучше понять, как загрязнение меняется не только по площади, но и по почвенному профилю.

Литература

1. Азаров А.В., Сердюков А.С., Сказка В.В. Теоретические исследования возможности использования туннельных волн для мониторинга состояния массива горных пород вблизи подземных сооружений // Горный информационно-аналитический бюллетень. – 2024. – № 4. – С. 155–167. DOI: 10.25018/0236_1493_2024_4_0_155.
2. Затонский А. В., Кузнецов С. В., Саломатова К. А. Улучшение качества распознавания параметров флотомшины с использованием нейронной сети // Горный информационно-аналитический бюллетень. – 2025. – № 6. – С. 153–167. DOI: 10.25018/0236_1493_2025_6_0_153.
3. Ключев Р.В., Мартюшев Н.В., Кукарцев В.В., Кукарцев В.А., Бригида В.С. Анализ геологической информации для обеспечения устойчивого функционирования горнотехнических систем // Горный информационно-аналитический бюллетень. – 2024. – № 5. – С. 144–157. DOI: 10.25018/0236_1493_2024_5_0_144.
4. Маслов А.М., Орлов А.С. Анализ потенциальных экологических рисков при применении способа гидроразрыва пласта // Горный информационно-аналитический бюллетень. – 2026. – № 1. – С. 59–70. DOI: 10.25018/0236_1493_2026_1_0_59.
5. Нурпеисова М.Б., Бурханов Б.Ж., Федотенко Н.А., Назаров Е.А. Мониторинг загрязнения почвенного покрова нефтепродуктами и разработка способа его рекультивации // Устойчивое развитие горных территорий. – 2023. – Т. 15. № 4. – С. 833–841. DOI: 10.21177/1998-4502-2023-15-4-833-841.
6. Татаринцев В.Л., Татаринцев Л.М., Лебедева Л.В. Оценка экологической реакции пшеницы мягкой яровой (*Triticum aestivum* L.) на воздействие разных факторов // Устойчивое развитие горных территорий. – 2026. – Т. 18. № 1. – С. 81–94. DOI: 10.21177/1998-4502-2026-18-1-81-94.
7. Толубекова Ж.З., Тиреуов К.М., Курмангалиева З.Н., Татаринцев В.Л. Экологическая реакция сельскохозяйственных культур на условия выращивания как основа управления устойчивостью агроландшафтов // Устойчивое развитие горных территорий. – 2025. – Т. 17. № 2. – С. 701–712. DOI: 10.21177/1998-4502-2025-17-2-701-712.
8. Banaee M., Zeidi A., Faggio C. Application of artificial intelligence and machine learning in computational toxicology in aquatic toxicology // Pollution. 2024. Vol. 10. No. 1. pp. 210–235. DOI: 10.22059/POLL.2023.362695.2003.
9. Barathkumar S., Devi A. Modeling and prediction of water quality using artificial intelligence techniques for enhanced monitoring and management // Water Environment Research. 2025. Vol. 97. No. 7. Art. No. e70143. DOI: 10.1002/wer.70143.
10. Didmanidze O.N., Karelina M.Yu., Klyuev R.V., Martyushev N.V., Serdechnyy D.V. Application of artificial intelligence and modern technologies in geomonitoring to improve the efficiency of the mining industry utilising the Earth's resources // News of the National Academy of Sciences of the Republic of Kazakhstan, Series of Geology and Technical Sciences. 2025. No. 470. pp. 84–96. DOI: 10.32014/2025.2518-170X.492.
11. Fomina E.V., Voitovich E.V., Brukhanov O. Some aspects on improvement of water resistant performance of gypsum binders // MATEC Web of Conferences. 2016. Vol. 86. Art. No. 04065. DOI: 10.1051/mateconf/20168604065.
12. Garcia A., Saez Y., Harris I., Huang X., Collado E. Advancements in air quality monitoring: a systematic review of IoT-based air quality monitoring and AI technologies // Artificial Intelligence Review. 2025. Vol. 58. No. 9. Art. No. 275. DOI: 10.1007/s10462-025-11277-9.
13. Hao J., Epstein S.A., Lavrinenko A.A., Fomina E.G. Kinetic test to estimate mobility of macro- and micro-elements in composition of solid coal refuse // MIAB. Mining Informational and Analytical Bulletin. 2025. No. 1. pp. 5–19. DOI: 10.25018/0236_1493_2025_1_0_5.

14. Karshyga Z.B., Ultarakova A.A., Lokhova N.G., Kassymzhanov K.K., Myrzakulov M. Technology for complex processing of electric smelting dusts of ilmenite concentrates to produce titanium dioxide and amorphous silica // *Metals*. 2022. Vol. 12. No. 12. Art. No. 2129. DOI: 10.3390/met12122129.
15. Kulikova E.Yu., Balovtsev S.V., Skopintseva O.V. Geoecological monitoring during mining operations // *Sustainable Development of Mountain Territories*. 2024. Vol. 16. No. 2. pp. 580–588. DOI: 10.21177/1998-4502-2024-16-2-580-588.
16. Ospanova A.A., Ozeranskaya N.L., Tatarintsev V.L., Shakenova Z.K. Modeling of environmentally sustainable agricultural land use in the Pavlodar region of Kazakhstan // *Sustainable Development of Mountain Territories*. 2025. Vol. 17. No. 4. pp. 1969–1976. DOI: 10.21177/1998-4502-2025-17-4-1969-1976.
17. Shukla K.K., Gupta A., Arora S.V., Rai H.M., Sharma G., Nivetha A. Environmental monitoring and protection using artificial intelligence // In: *AIP Conference Proceedings*. 2025. Vol. 3297. No. 1. Art. No. 0285889. DOI: 10.1063/5.0285889.
18. Sumi A.M., Chandrasekar K.S. Artificial intelligence for sustainable stewardship of Earth resources // *Data Analytics and Artificial Intelligence for Earth Resource Management*. 2024. pp. 65–75. DOI: 10.1016/B978-0-443-23595-5.00004-8.
19. Wijaya J., Park J., Yang Y., Siddiqui S.I., Oh S. A metagenome-derived artificial intelligence modeling framework advances the predictive diagnosis and interpretation of petroleum-polluted groundwater // *Journal of Hazardous Materials*. 2024. Vol. 472. Art. No. 134513. DOI: 10.1016/j.jhazmat.2024.134513.
20. Yelemessov K.K., Myrzakulov M., Yerezhep D.E., Tkachenko D.E., Kuldeyev N. Y. Analytical assessment of rotor profiles on three-screw compressor performance for gas field operations: circular-arc versus cycloidal // *News of the National Academy of Sciences of the Republic of Kazakhstan, Series of Geology and Technical Sciences*. 2026. Vol. 2026. No. 3. pp. 377–391. DOI: 10.32014/2026.2518-170X.659.

References

1. Azarov A.V., Serdyukov A.S., Skazka V.V. Theoretical investigation of usability of tunnel waves in rock mass monitoring near underground structures. *MIAB. Mining Informational and Analytical Bulletin*. 2024. No. 4. pp. 155–167. DOI: 10.25018/0236_1493_2024_4_0_155. (In Russ.)
2. Zatonskiy A.V., Kuznetsov S.V., Salomatova K.A. Improvement of detection quality for parameters of flotation machines using neural network. *MIAB. Mining Informational and Analytical Bulletin*. 2025. No. 6. pp. 153–167. DOI: 10.25018/0236_1493_2025_6_0_153. (In Russ.)
3. Klyuev R.V., Martyushev N.V., Kukartsev V.V., Kukartsev V.A., Brigida V. S. Analysis of geological information toward sustainable performance of geotechnical systems. *Mining Informational and Analytical Bulletin*. 2024. No. 5. pp. 144–157. DOI: 10.25018/0236_1493_2024_5_0_144. (In Russ.)
4. Maslov A.M., Orlov A.S. Potential ecological risks of hydraulic fracturing. *MIAB. Mining Informational and Analytical Bulletin*. 2026. No. 1. pp. 59–70. DOI: 10.25018/0236_1493_2026_1_0_59. (In Russ.)
5. Nurpeissova M.B., Burkhanov B.Zh., Fedotenko N.A., Nazarov E.A. Assessment of oil waste as a source of environmental pollution and as a source of secondary raw materials. *Sustainable Development of Mountain Territories*. 2023. Vol. 15. No. 4. pp. 833–841. DOI: 10.21177/1998-4502-2023-15-4-833-841. (In Russ.)
6. Tatarintsev V.L., Tatarintsev L.M., Lebedeva L.V. Assessment of the ecological reaction of soft spring wheat (*Triticum aestivum* L.) to the effects of various factors. *Sustainable Development of Mountain Territories*. 2026. Vol. 18. No. 1. pp. 81–94. DOI: 10.21177/1998-4502-2026-18-1-81-94. (In Russ.)
7. Toleubekova Z.Z., Tireuov K.M., Kurmangalieva Z.N., Tatarintsev V.L. Ecological response of agricultural crops to growing conditions as a basis for managing the sustainability of agricultural landscapes. *Sustainable Development of Mountain Territories*. 2025. Vol. 17. No. 2. pp. 701–712. DOI: 10.21177/1998-4502-2025-17-2-701-712. (In Russ.)
8. Banae M., Zeidi A., Faggio C. Application of artificial intelligence and machine learning in computational toxicology in aquatic toxicology. *Pollution*. 2024. Vol. 10. No. 1. pp. 210–235. DOI: 10.22059/POLL.2023.362695.2003.

9. Barathkumar S., Devi A. Modeling and prediction of water quality using artificial intelligence techniques for enhanced monitoring and management. *Water Environment Research*. 2025. Vol. 97. No. 7. Art. No. e70143. DOI: 10.1002/wer.70143.
10. Didmanidze O.N., Karelina M.Yu., Klyuev R.V., Martyshev N.V., Serdechnyy D.V. Application of artificial intelligence and modern technologies in geomonitoring to improve the efficiency of the mining industry utilising the Earth's resources. *News of the National Academy of Sciences of the Republic of Kazakhstan, Series of Geology and Technical Sciences*. 2025. No. 470. pp. 84–96. DOI: 10.32014/2025.2518-170X.492.
11. Fomina E.V., Voitovich E.V., Brukhanov O. Some aspects on improvement of water resistant performance of gypsum binders. *MATEC Web of Conferences*. 2016. Vol. 86. Art. No. 04065. DOI: 10.1051/mateconf/20168604065.
12. Garcia A., Saez Y., Harris I., Huang X., Collado E. Advancements in air quality monitoring: a systematic review of IoT-based air quality monitoring and AI technologies. *Artificial Intelligence Review*. 2025. Vol. 58. No. 9. Art. No. 275. DOI: 10.1007/s10462-025-11277-9.
13. Hao J., Epstein S.A., Lavrinenko A.A., Fomina E.G. Kinetic test to estimate mobility of macro- and micro-elements in composition of solid coal refuse. *MIAB. Mining Informational and Analytical Bulletin*. 2025. No. 1. pp. 5–19. DOI: 10.25018/0236_1493_2025_1_0_5.
14. Karshyga Z.B., Ultarakova A.A., Lokhova N.G., Kassymzhanov K.K., Myrzakulov M. Technology for complex processing of electric smelting dusts of ilmenite concentrates to produce titanium dioxide and amorphous silica. *Metals*. 2022. Vol. 12. No. 12. Art. No. 2129. DOI: 10.3390/met12122129.
15. Kulikova E.Yu., Balovtsev S.V., Skopintseva O.V. Geoecological monitoring during mining operations. *Sustainable Development of Mountain Territories*. 2024. Vol. 16. No. 2. pp. 580–588. DOI: 10.21177/1998-4502-2024-16-2-580-588.
16. Ospanova A.A., Ozeranskaya N.L., Tatarintsev V.L., Shakenova Z.K. Modeling of environmentally sustainable agricultural land use in the Pavlodar region of Kazakhstan. *Sustainable Development of Mountain Territories*. 2025. Vol. 17. No. 4. pp. 1969–1976. DOI: 10.21177/1998-4502-2025-17-4-1969-1976.
17. Shukla K.K., Gupta A., Arora S.V., Rai H.M., Sharma G., Nivetha A. Environmental monitoring and protection using artificial intelligence. In: *AIP Conference Proceedings*. 2025. Vol. 3297. No. 1. Art. No. 0285889. DOI: 10.1063/5.0285889.
18. Sumi A.M., Chandrasekar K.S. Artificial intelligence for sustainable stewardship of Earth resources // *Data Analytics and Artificial Intelligence for Earth Resource Management*. 2024. pp. 65–75. DOI: 10.1016/B978-0-443-23595-5.00004-8.
19. Wijaya J., Park J., Yang Y., Siddiqui S.I., Oh S. A metagenome-derived artificial intelligence modeling framework advances the predictive diagnosis and interpretation of petroleum-polluted groundwater. *Journal of Hazardous Materials*. 2024. Vol. 472. Art. No. 134513. DOI: 10.1016/j.jhazmat.2024.134513.
20. Yelemessov K.K., Myrzakulov M., Yerezhep D.E., Tkachenko D.E., Kuldeyev N. Y. Analytical assessment of rotor profiles on three-screw compressor performance for gas field operations: circular-arc versus cycloidal. *News of the National Academy of Sciences of the Republic of Kazakhstan, Series of Geology and Technical Sciences*. 2026. Vol. 2026. No. 3. pp. 377–391. DOI: 10.32014/2026.2518-170X.659.