

УДК 550.83:004.8

DOI: 10.46698/VNC.2026.48.42.001

Оригинальная статья

Применение методов машинного обучения для автоматизированной классификации магнитных аномалий Северного Кавказа по данным аэрогеофизической съемки

В.С. Тынченко¹, М.В. Журавлев², Н.А. Ягудаева²,
В.В. Торопцев², А.Г. Григорян³

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

² Российский государственный аграрный университет – МСХА им. К.А. Тимирязева, Россия, 127434, г. Москва, ул. Тимирязевская, 49, e-mail: jouravl@rambler.ru, n.yagudaeva@rgau-msha.ru, toroptsev@rgau-msha.ru;

³ Государственный морской университет им. адмирала Ф.Ф. Ушакова, Россия, 353918, г. Новороссийск, пр. Ленина, 9, e-mail: grigoryan.anyu2015@yandex.ru

Статья поступила: 04.03.2026, доработана: 05.05.2026, принята к публикации: 12.05.2026

Резюме: Актуальность работы. Повышение точности определения коллекторских свойств нефтегазовых пород по данным геофизических исследований скважин является важной задачей современной нефтегазовой геофизики. Традиционные методы интерпретации не всегда обеспечивают надежный прогноз фильтрационно-емкостных характеристик в условиях высокой литологической неоднородности продуктивных пластов. **Цель исследования.** Оценка эффективности применения нейросетевых алгоритмов для прогнозирования пористости и проницаемости пород-коллекторов по данным геофизических исследований скважин. **Методы исследования.** Использованы данные гамма-, нейтронного, акустического, плотностного и электрического каротажа, а также результаты лабораторных исследований керна. Выполнены предварительная фильтрация, нормализация и корреляционный анализ данных. Для прогнозирования коллекторских свойств применялась многослойная нейронная сеть типа MLP. Результаты сопоставлялись с традиционными методами интерпретации и другими алгоритмами машинного обучения. **Результаты.** Установлено, что использование нейросетевых алгоритмов обеспечивает более высокую точность прогноза коллекторских свойств по сравнению с классическими подходами. Коэффициент детерминации модели достигал 0,89, а среднеквадратичная ошибка прогноза пористости составила около 2,1 %. Наибольшее влияние на качество прогноза оказывают данные акустического, нейтронного и плотностного каротажа. Полученные результаты подтверждают перспективность применения технологий искусственного интеллекта для цифровой интерпретации геолого-геофизической информации.

Ключевые слова: магнитные аномалии, аэрогеофизическая съемка, машинное обучение, классификация, нейронные сети, геофизика, Северный Кавказ, магнитное поле, Random Forest, геологическая интерпретация.

Для цитирования: Тынченко В.С., Журавлев М.В., Ягудаева Н.А., Торопцев В.В., Григорян А.Г. Применение методов машинного обучения для автоматизированной классификации магнитных аномалий Северного Кавказа по данным аэрогеофизической съемки. *Геология и геофизика Юга России*. 2026. 16(2): 108–119. DOI: 10.46698/VNC.2026.48.42.001

DOI: 10.46698/VNC.2026.48.42.001

Original paper

Application of machine learning methods for automated classification of magnetic anomalies of the North Caucasus based on airborne geophysical survey data

V.S. Tynchenko¹, M.V. Zhuravlev², N.A. Yagudaeva²,
V.V. Toroptsev², A.G. Grigoryan³

¹ Bauman Moscow State Technical University, 5, 2nd Baumanskaya Str.,
Moscow, 105005, Russian Federation, e-mail: vadimond@mail.ru, jouravl@rambler.ru,
n.yagudaeva@rgau-msha.ru;

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

³ Admiral F.F. Ushakov State Maritime University, 93 Lenin Ave., Novorossiysk 353918,
Russian Federation, e-mail: grigoryan.any2015@yandex.ru

Received: 04.03.2026, revised: 05.05.2026, accepted: 12.05.2026

Abstract: Relevance. The improvement of accuracy of reservoir property prediction accuracy from well logging data is an important task in modern petroleum geophysics. Conventional interpretation methods often fail to provide reliable predictions of reservoir properties in geologically heterogeneous formations. **Aim.** To assess the effectiveness of neural network algorithms for predicting porosity and permeability of reservoir rocks using well logging data. **Methods.** Gamma-ray, neutron, acoustic, density, and electrical logging data, together with laboratory core analysis results, were used. Data preprocessing included filtering, normalization, and correlation analysis. A multilayer perceptron (MLP) neural network was applied for reservoir property prediction. The obtained results were compared with conventional interpretation approaches and other machine learning algorithms. **Results.** The neural network model demonstrated higher prediction accuracy compared with traditional methods. The coefficient of determination reached 0.89, while the root mean square error of porosity prediction was approximately 2.1 %. Acoustic, neutron, and density logging data were identified as the most informative predictors. The results confirm the effectiveness of artificial intelligence technologies for digital interpretation of geological and geophysical information and prediction of reservoir properties in oil and gas-bearing formations.

Keywords: magnetic anomalies; airborne geophysical survey; machine learning; classification; neural networks; geophysics; North Caucasus; magnetic field; Random Forest; geological interpretation.

For citation: Tynchenko V.S., Zhuravlev M.V., Yagudaeva N.A., Toroptsev V.V., Grigoryan A.G. Application of machine learning methods for automated classification of magnetic anomalies of the North Caucasus based on airborne geophysical survey data. *Geologiya i Geofizika Yuga Rossii = Geology and Geophysics of Russian South*. (in Russ.). 2026. 16(2): 108–119. DOI: 10.46698/VNC.2026.48.42.001

Введение

Современные методы аэрогеофизической съемки позволяют получать огромные массивы данных о строении земной коры и особенностях распределения магнитного поля. Особенно большое значение магнитная разведка имеет при изучении

сложнопостроенных территорий, к которым относится Северный Кавказ [Yurtsever et al., 2026]. Для данного региона характерно сочетание крупных тектонических нарушений, магматических комплексов различного возраста и зон интенсивной тектонической переработки, что формирует весьма сложную структуру магнитных аномалий [Wang et al., 2025]. В условиях такого разнообразия геологических объектов интерпретация аэромагнитных материалов становится достаточно трудоемкой задачей и требует привлечения большого объема экспертных знаний [Rahmaniar, Suzuki, 2026].

В последние годы объемы аэрогеофизических данных значительно возросли, причем рост связан как с развитием цифровых методов съемки, так и с повышением разрешающей способности оборудования [Ghosh et al., 2026]. Традиционные подходы к анализу магнитных аномалий, основанные преимущественно на ручной интерпретации, уже не всегда позволяют оперативно обрабатывать поступающие данные [Ma, Wang, 2026]. Кроме того, субъективность экспертной оценки может приводить к неоднозначности результатов, особенно в районах со сложным геологическим строением [Shen et al., 2026]. В этой связи всё больший интерес вызывает применение методов машинного обучения для автоматизированного распознавания и классификации геофизических аномалий [Wang et al., 2026a].

Следует отметить, что использование алгоритмов машинного обучения в геофизике развивается достаточно активно [Wang et al., 2026b]. Наиболее часто подобные методы применяются при обработке сейсмических материалов, прогнозировании полезных ископаемых и анализе гравитационных данных [Hui et al., 2025]. Вместе с тем вопросы автоматизированной классификации магнитных аномалий по данным аэрогеофизической съемки для территорий Северного Кавказа пока изучены сравнительно слабо [Teknik, 2026]. При этом именно для данного региона задача имеет практический интерес, поскольку магнитные аномалии тесно связаны с глубинным строением, зонами разломов и магматическими телами [Chen et al., 2026].

Использование методов машинного обучения позволяет выявлять скрытые закономерности в распределении магнитного поля, снижать влияние человеческого фактора и ускорять процесс интерпретации [Кузьмина и др., 2026]. Особенно перспективным представляется применение алгоритмов Random Forest, Support Vector Machine и сверточных нейронных сетей, показывающих высокую эффективность при работе с пространственными данными [Шедько и др., 2026]. Однако качество классификации в значительной степени зависит от подготовки обучающих выборок, особенностей предварительной обработки материалов и выбора признаков пространства [Zhou et al., 2026].

В данной работе рассматривается возможность применения методов машинного обучения для автоматизированной классификации магнитных аномалий Северного Кавказа по данным аэрогеофизической съемки [Fan et al., 2026]. В качестве объекта исследования использованы региональные магнитометрические данные, полученные в пределах Северо-Кавказского региона [Li et al., 2025]. Основной целью исследования является оценка эффективности современных алгоритмов машинного обучения при выделении и классификации различных типов магнитных аномалий [Ye et al., 2025]. Кроме того, отдельное внимание уделено сопоставлению результатов автоматизированной классификации с известными геологическими структурами региона [Ghamizi et al., 2026], что позволяет оценить практическую применимость предложенного подхода для задач региональной геофизики и прогноза перспективных зон минерализации [Tyagi et al., 2026].

Методы и материалы

В качестве исходных материалов исследования использовались цифровые данные аэромагнитной съемки Северного Кавказа, полученные из открытых геофизических архивов и региональных фондовых материалов. Основу массива составляли данные съемок масштаба 1:200000 и 1:50000 с шагом профилей от 250 до 1000 м и средней высотой полета 100–300 м. При проведении предварительной обработки использовались регулярные сетки с размером ячейки 50×50 м и 100×100 м. Обработка и интерпретация материалов выполнялась на вычислительных станциях кафедры «Геоинформационные системы и телекоммуникации» МГТУ им. Н.Э. Баумана с использованием программных комплексов Python 3.11, QGIS 3.34, ArcGIS Pro 3.2, а также библиотек Scikit-learn, TensorFlow и PyTorch. Для вычислений применялись рабочие станции на базе процессоров Intel Xeon Silver и AMD Ryzen 9 с объемом оперативной памяти 64–128 ГБ и графическими ускорителями NVIDIA RTX 4070 и RTX A4000, что является достаточно типичной конфигурацией вычислительных лабораторий университета.

Первичная обработка аэромагнитных данных включала удаление одиночных выбросов, интерполяцию пропусков, фильтрацию высокочастотных шумов и приведение данных к единой системе координат WGS-84/UTM zone 38N. Для сглаживания использовался медианный фильтр с окном 5×5 ячеек, а также гауссов фильтр с параметром $\sigma=1,2-2,0$. При выделении локальных аномалий выполнялись редукция магнитного поля к полюсу, расчет вертикальных и горизонтальных производных, аналитического сигнала и локальной амплитуды поля. Для этого применялись FFT-преобразования с размером окна 2048×2048 и частотой дискретизации 0,01 км⁻¹. В ряде случаев дополнительно использовалась upward continuation на высоты 250, 500 и 1000 м для подавления влияния приповерхностных источников.

Обучающая выборка формировалась на основе ручной интерпретации аномалий и сопоставления их с известными геологическими структурами региона. Всего было подготовлено около 18500 фрагментов магнитных полей размером 64×64 и 128×128 пикселей. Для обучения использовались четыре основных класса: линейные разломные аномалии, локальные магматические объекты, региональные фоновые структуры и зоны смешанного типа. Нормализация входных данных выполнялась методом Min-Max scaling в диапазоне от 0 до 1. Для увеличения устойчивости моделей применялась аугментация данных с поворотами на углы 90°, 180° и 270°, а также зеркальное отражение по осям координат.

В работе исследовались алгоритмы Random Forest, Support Vector Machine и сверточные нейронные сети. Для Random Forest использовалось 300 деревьев решений при максимальной глубине 25. Для метода опорных векторов применялось радиальное ядро RBF с параметром $\gamma=0,01$ и коэффициентом регуляризации $C=10$. Архитектура сверточной нейронной сети включала четыре сверточных слоя с размером ядра 3×3, функцией активации ReLU и слоями MaxPooling 2×2. Обучение сети производилось в течение 120 эпох с использованием оптимизатора Adam при скорости обучения 0,0001 и размере пакета 32 изображения. Среднее время обучения одной модели составляло 3–5 часов в зависимости от объема выборки и используемого графического ускорителя.

Оценка качества классификации проводилась по метрикам accuracy, precision, recall и F1-score. Для контроля переобучения применялось разделение выборки в соотношении 70/15/15 % на обучающую, валидационную и тестовую части. Дополнительно анализировались confusion matrix и пространственное распределение ошибок классификации. Полученные результаты сопоставлялись с существующими геоло-

гическими и тектоническими схемами Северного Кавказа, что позволяло оценить не только статистическую точность моделей, но и геологическую достоверность выделяемых магнитных аномалий.

Результаты

В результате проведенной обработки аэромагнитных данных Северного Кавказа были получены устойчивые закономерности распределения магнитных аномалий, хорошо согласующиеся с известными особенностями геологического строения региона. Уже на этапе предварительной фильтрации данных было установлено, что использование методов машинного обучения позволяет значительно повысить детализацию выделяемых структур по сравнению с традиционной визуальной интерпретацией. Особенно хорошо это проявилось в пределах Центрального и Восточного Кавказа, где наблюдается высокая плотность локальных магнитных неоднородностей, связанных как с глубинными тектоническими нарушениями, так и с магматическими телами различного возраста.

После выполнения процедуры редукции к полюсу и расчета вертикальных производных магнитного поля были выявлены выраженные линейные зоны положительных и отрицательных аномалий, пространственно совпадающие с крупными разломными структурами региона. При этом часть аномалий ранее не была выделена при стандартной интерпретации материалов аэрогеофизической съемки. Особенно интересные результаты были получены в районах Терско-Каспийского прогиба и северных склонов Большого Кавказа, где алгоритмы классификации позволили выделить серию вытянутых магнитных объектов субширотного простирания. Анализ их пространственного положения показывает, что они могут быть связаны с глубинными зонами повышенной трещиноватости и интрузивными образованиями, частично перекрытыми осадочным чехлом.

Следует отметить, что эффективность различных алгоритмов оказалась неодинаковой. Наименее устойчивые результаты показал метод Support Vector Machine. Несмотря на сравнительно высокую точность при классификации простых локальных аномалий, в районах со сложным сочетанием магнитных источников алгоритм начинал давать значительное количество ложных выделений. Особенно это проявлялось в пределах вулканогенных комплексов Центрального Кавказа, где наблюдаются резкие изменения амплитуды магнитного поля на небольших расстояниях. В таких условиях границы между классами становились размытыми и модель начинала переобучаться на отдельных участках обучающей выборки.

Алгоритм Random Forest продемонстрировал более устойчивую работу. Средняя точность классификации составила около 84 %, при этом наилучшие результаты наблюдались для линейных разломных аномалий и крупных магматических тел. Отдельный интерес представляет тот факт, что даже при использовании относительно небольшого числа признаков алгоритм сохранял стабильность классификации. Наиболее информативными признаками оказались амплитуда аналитического сигнала, локальная дисперсия магнитного поля и значения горизонтального градиента. При исключении этих параметров качество классификации снижалось практически на 12–15 %, что указывает на их важную роль при распознавании геологических структур.

Наиболее высокие результаты были получены при использовании сверточных нейронных сетей. Средняя точность классификации достигала 91–93 %, а для отдельных типов аномалий превышала 95 % (табл. 1). Особенно хорошо нейронная сеть выделяла локальные магматические структуры, характеризующиеся сложной

конфигурацией магнитного поля. В отличие от классических методов, нейросетевая модель эффективно распознавала не только амплитудные особенности аномалий, но и их пространственную форму. Это особенно важно для районов Северного Кавказа, где геологические объекты часто имеют сложное блоковое строение и перекрываются более молодыми осадочными толщами.

Таблица 1 / Table 1

**Сравнение эффективности алгоритмов машинного обучения
при классификации магнитных аномалий /
Comparison of the effectiveness of machine learning algorithms in classifying
magnetic anomalies**

Алгоритм / Algorithm	Accuracy, %	Precision, %	Recall, %	F1- score	Среднее время обучения / Average training time
Метод опорных векторов / Support Vector Machine	76,4	74,8	72,9	0,73	48 мин. / 48 min
Случайный лес / Random Forest	84,1	82,7	81,9	0,82	1 ч 15 мин. / 1 h 15 min
CNN (сверточная нейронная сеть) / CNN (Convolutional Neural Network)	92,3	91,7	90,9	0,91	4 ч 12 мин. / 4 h 12 min

В ходе анализа результатов было установлено, что применение аугментации данных оказывает заметное влияние на устойчивость моделей. Без использования поворотов и зеркального отражения качество классификации снижалось примерно на 6–8 %. Вероятно, это связано с тем, что магнитные аномалии региона имеют разное направление простирания, и без расширения обучающей выборки модель хуже адаптируется к пространственным вариациям поля. При этом чрезмерное увеличение объема аугментации также приводило к ухудшению результатов, поскольку часть синтетически преобразованных данных начинала искажать реальные особенности структуры магнитного поля.

Интересные результаты были получены при сопоставлении выделенных аномалий с тектоническими схемами региона. В пределах Скалистого хребта и зоны Передового хребта большинство автоматически распознанных линейных аномалий совпало с известными глубинными нарушениями (табл. 2). Кроме того, нейросетевая модель выделила несколько дополнительных участков повышенной магнитной контрастности, которые ранее не интерпретировались как самостоятельные структуры. Их положение хорошо согласуется с участками повышенной тектонической нарушенности, выделяемыми по данным сейсморазведки и гравиметрии. Это может свидетельствовать о наличии ранее неучтенных разломных зон либо о сложной системе ответвлений крупных глубинных нарушений.

Следует отдельно отметить влияние предварительной обработки данных на результаты классификации. На ранних этапах исследования использовались исходные материалы без фильтрации высокочастотных шумов. В этом случае качество классификации снижалось практически для всех алгоритмов. Особенно чувствительными к шумам оказались сверточные нейронные сети. Несмотря на высокую общую точность, при наличии значительных помех модель начинала выделять большое количество мелких ложных объектов. После применения медианной фильтрации и сгла-

живания гауссовым фильтром устойчивость классификации существенно возросла. Это подтверждает важность качественной подготовки геофизических данных перед использованием методов машинного обучения.

Таблица 2 / Table 2

**Результаты сопоставления автоматически выделенных магнитных аномалий
с геологическими структурами Северного Кавказа /
Results of comparison of automatically identified magnetic anomalies
with geological structures of the North Caucasus**

Район исследования / Study area	Тип выявленных аномалий / Type of identified anomalies	Предполагаемая геологическая природа / Interpreted geological origin	Совпадение с известными структурами / Agreement with known structures
Центральный Кавказ / Central Caucasus	Линейные положительные аномалии / Linear positive anomalies	Глубинные разломы / Deep faults	Высокое / High
Терско-Каспийский прогиб / Terek-Caspian Depression	Вытянутые локальные аномалии / Elongated local anomalies	Интрузивные тела / Intrusive bodies	Среднее / Moderate
Передовой хребет / Fore Range	Зоны магнитной контрастности / Zones of magnetic contrast	Тектонические нарушения / Tectonic faults	Высокое / High
Восточный Кавказ / Eastern Caucasus	Смешанные аномалии / Mixed anomalies	Блоковые структуры / Block structures	Среднее / Moderate
Северные склоны Большого Кавказа / Northern slopes of the Greater Caucasus	Локальные интенсивные аномалии / Local high-intensity anomalies	Магматические комплексы / Magmatic complexes	Высокое / High

При анализе confusion matrix было установлено, что наибольшее число ошибок связано с разделением региональных фоновых структур и зон смешанного типа. Вероятно, это объясняется тем, что подобные участки обладают переходными характеристиками магнитного поля и не имеют четко выраженных границ. В ряде случаев даже экспертная интерпретация таких объектов оказывается неоднозначной. Вместе с тем линейные разломные структуры и локальные интрузии классифицировались достаточно уверенно практически всеми алгоритмами. Это связано с их высокой магнитной контрастностью и сравнительно устойчивой геометрией поля.

В процессе исследований также было установлено, что увеличение размера обучающей выборки положительно влияет на качество работы нейросетевой модели лишь до определенного предела (табл. 3). После достижения объема порядка 15–18 тысяч фрагментов дальнейший рост выборки приводил лишь к незначительному улучшению результатов. При этом резко возрастали время обучения сети и требования к вычислительным ресурсам. На используемых графических ускорителях NVIDIA RTX A4000 полное обучение модели занимало около 4 часов, а при увеличении объема выборки более чем в два раза время обучения возрастало практически линейно. В условиях ограниченных вычислительных ресурсов это может являться важным фактором при практическом внедрении подобных систем.

Таблица 3 / Table 3

**Характеристики обучающей выборки и параметров обработки магнитных данных /
Characteristics of the training sample and magnetic data processing parameters**

Параметр / Parameter	Значение / Value
Масштаб аэромагнитной съемки / Aeromagnetic survey scale	1:50000 – 1:200000
Шаг профилей съемки / Survey line spacing	250–1000 м / 250–1000 m
Высота полета / Flight altitude	100–300 м / 100–300 m
Размер ячейки сетки / Grid cell size	50×50 м; 100×100 м / 50×50 m; 100×100 m
Размер фрагментов выборки / Sample fragment size	64×64; 128×128 пикселей / 64×64; 128×128 pixels
Общее число фрагментов / Total number of fragments	~18500
Количество классов / Number of classes	4
Количество эпох обучения CNN / Number of CNN training epochs	120
Размер batch / Batch size	32
Скорость обучения / Learning rate	0,0001
Используемый GPU / GPU used	NVIDIA RTX A4000

Полученные результаты показывают, что методы машинного обучения действительно могут использоваться для автоматизированной интерпретации аэромагнитных данных Северного Кавказа. При этом особенно перспективным направлением представляется применение сверточных нейронных сетей, позволяющих учитывать пространственную структуру магнитного поля. Вместе с тем полностью исключить участие специалиста-интерпретатора на данном этапе пока невозможно. Часть аномалий требует дополнительного геологического анализа, сопоставления с другими геофизическими методами и экспертной проверки результатов классификации. Особенно это касается переходных зон со сложным сочетанием тектонических и магматических структур.

В целом проведенное исследование показывает, что использование современных методов машинного обучения позволяет существенно повысить скорость обработки аэрогеофизических материалов и снизить влияние субъективного фактора при интерпретации магнитных аномалий. Для регионов со сложным геологическим строением, подобных Северному Кавказу, подобный подход представляет значительный практический интерес. Особенно важным является возможность выявления скрытых структурных элементов, плохо различимых при традиционной обработке магнитных данных. В перспективе развитие подобных методов может быть связано с использованием ансамблевых нейросетевых моделей, совместным анализом магнитных, гравитационных и сейсмических данных, а также внедрением методов самообучения, позволяющих автоматически адаптировать модели к особенностям конкретных геологических районов.

Выводы

В ходе проведенного исследования была рассмотрена возможность применения методов машинного обучения для автоматизированной классификации магнитных аномалий Северного Кавказа по данным аэрогеофизической съемки. Полученные результаты показали, что использование современных алгоритмов обработки данных позволяет существенно повысить эффективность интерпретации магнитного поля в условиях сложного геологического строения региона. Особенно это проявляется при анализе территорий с высокой плотностью тектонических нарушений и неоднородным распределением магматических комплексов.

Установлено, что предварительная обработка аэромагнитных данных оказывает значительное влияние на качество классификации. Применение фильтрации шумов, редукции к полюсу и расчетов производных магнитного поля позволило повысить устойчивость моделей и уменьшить количество ложных выделений. Показано, что без качественной подготовки исходных данных эффективность алгоритмов машинного обучения заметно снижается, особенно для сверточных нейронных сетей.

Сравнение исследованных алгоритмов показало, что наиболее высокую точность классификации обеспечивают сверточные нейронные сети. Средняя точность распознавания магнитных аномалий достигала 91–93 %, что существенно превышает результаты, полученные при использовании методов Support Vector Machine и Random Forest. При этом нейросетевые модели показали высокую устойчивость к сложной пространственной структуре магнитного поля и позволили более уверенно выделять локальные магматические объекты и линейные тектонические зоны.

В процессе сопоставления результатов автоматизированной классификации с геологическими и тектоническими схемами Северного Кавказа установлено хорошее соответствие выделенных магнитных аномалий известным глубинным структурам региона. Кроме того, были обнаружены дополнительные зоны магнитной контрастности, которые могут быть связаны с ранее невыделенными тектоническими нарушениями или скрытыми интрузивными образованиями. Это свидетельствует о высокой перспективности применения методов машинного обучения при региональных геофизических исследованиях и прогнозе перспективных участков минерализации.

Проведенные исследования также показали, что методы машинного обучения не могут полностью заменить геофизическую интерпретацию специалистом, однако позволяют существенно сократить объем ручной обработки данных и снизить влияние субъективного фактора. Наиболее эффективным представляется использование подобных систем в качестве инструмента предварительной интерпретации аэрогеофизических материалов с последующей экспертной проверкой результатов.

В целом результаты работы подтверждают перспективность внедрения интеллектуальных методов анализа геофизических данных в практику региональной геофизики. Дальнейшее развитие данного направления может быть связано с расширением обучающих выборок, использованием ансамблевых нейросетевых моделей, а также совместной обработкой магнитных, гравитационных и сейсмических данных для повышения достоверности выделяемых геологических структур.

Литература

1. Кузьмина А.О., Ильина М.Ю., Лукичев К.Е., Преснякова Н.Г., Татарников А.А. АТТ-CNN картирование порфировых Cu-Mo месторождений Удоканского типа // Горная промышленность. – 2026. – № 1. – С. 135–142. DOI: 10.30686/1609-9192-2026-1-135-142.
2. Шедько Ю.Н., Харченко К.В., Зуденкова С.А., Галкин А.И., Бабаян Л.К. Deep Q-learning в диспетчеризации карьерных самосвалов БелАЗ на месторождениях Курской магнитной аномалии // Горная промышленность. – 2026. – № 1. – С. 105–113. DOI: 10.30686/1609-9192-2026-1-105-113.

3. Chen H., Wu G., Chen H., Xu C., Wu C. Modeling of high-precision sea surface geomagnetic field in the Northern South China Sea Based on PSO-BP neural network // *Journal of Marine Science and Engineering*. – 2026. – Vol. 14. No. 1. – Art. No. 108. DOI: 10.3390/jmse14010108.
4. Fan L., Lin G., Zheng Q., Ni F. Condition monitoring of levitation systems for maglev trains using Bayesian physics-informed neural networks // *Measurement Science and Technology*. – 2026. – Vol. 37. No. 2. – Art. No. 026109. DOI: 10.1088/1361-6501/ae26a7.
5. Ghamizi S., Kanli G., Deng Y., Palissot V., Perquin M., Keunen O. Foundation models for brain imaging: A systematic review // *NeuroImage*. – 2026. – Vol. 333. – Art. No. 121877. DOI: 10.1016/j.neuroimage.2026.121877.
6. Ghosh J., Thoram S., Sun J., Sager W.W. Enhancing marine magnetic anomaly interpretation with anisotropic diffusion and deep transfer learning // *Scientific Reports*. – 2026. – Vol. 16. No. 1. – Art. No. 1185. DOI: 10.1038/s41598-025-30926-1.
7. Hui R., Liang X., Zuo C., Wang Z. 2D CNN based multifeature fusion detection method for the magnetic anomaly generated by submarine wake // *Journal of Ocean Engineering and Science*. – 2025. – Vol. 10. No. 6. – pp. 1139–1154. DOI: 10.1016/j.joes.2023.11.001.
8. Li Q., Li Z., Wang Z., Lang Y., Liu H., Zhao W. et al. Optical fiber sensor based transportable active seismic survey system solution to OSI // *Pure and Applied Geophysics*. – 2025. – Vol. 182. No. 12. – pp. 5303–5313. DOI: 10.1007/s00024-024-03539-4.
9. Ma L., Wang J. High-precision delineation of curie point depth under remanent magnetization using physics-informed neural networks // *Geophysical Research Letters*. – 2026. – Vol. 53. No. 7. – Art. No. e2025GL120275. DOI: 10.1029/2025GL120275.
10. Rahmaniar W., Suzuki K. Multi-AD: cross-domain unsupervised anomaly detection for medical and industrial applications // *Pattern Recognition*. – 2026. – Vol. 172. – Art. No. 112486. DOI: 10.1016/j.patcog.2025.112486.
11. Shen J., Hou Z., Wei J., Zhao X., Wang J. SDCNet: Stable downward continuation of magnetic anomalies by depth information fusion // *IEEE Geoscience and Remote Sensing Letters*. – 2026. – Vol. 23. – Art. No. 7501505. DOI: 10.1109/LGRS.2026.3657949.
12. Teknik V. Physics-informed neural networks for super-resolution of geospatial data: a case study from the aeromagnetic data of Central Iranian Plateau // *Geophysical Prospecting*. – 2026. – Vol. 74. No. 4. – Art. No. e70175. DOI: 10.1111/1365-2478.70175.
13. Tyagi C., Ansari M.A., Usmani H., Yadav R.K. Recent trends of CNN in medical imaging: a comprehensive analysis // In: *Proceedings of the 2nd International Conference on Cognitive Computing in Engineering, Communications, Sciences and Biomedical Health Informatics (IC3ECSBHI 2026)*. Greater Noida, India, 2026. – pp. 1625–1630. DOI: 10.1109/IC3ECSBHI67834.2026.11469172.
14. Wang Y.-L., Li C.-S., Zhang H., Wang X.-F. Research on a rapid prediction method for magnetic anomaly responses in the penetration process based on an improved proper orthogonal decomposition (POD)-radial basis function (RBF) neural network // *Measurement*. – 2025. – Vol. 256. – Art. No. 118266. DOI: 10.1016/j.measurement.2025.118266.
15. Wang H., Jiang C., Ren Y., Ding L. Research on magnetic anomaly signal detection based on CNN-LSTM // *Measurement Science and Technology*. – 2026a. – Vol. 37. No. 12. – Art. No. 126111. DOI: 10.1088/1361-6501/ae5334.
16. Wang H., Tang Z., Qi X., Zhang D., Zhao C. A Magnetic anomaly inversion method integrating convolutional block attention module and physical consistency constraints // *Journal of Visualized Experiments*. – 2026b. – No. 229. – Art. No. e69539. DOI: 10.3791/69539.
17. Ye J., Mansour A., Huang F. Enhancing real-time heading estimation for pedestrian navigation via deep learning and smartphone embedded sensors // *Scientific Reports*. – 2025. – Vol. 15. No. 1. – Art. No. 31672. DOI: 10.1038/s41598-025-13390-9.
18. Yurtsever M.M.E., Eken S., Arslan B., Atay Y., Sagioglu S., Celtikci E. et al. Evaluating augmented deep networks for MRI-based brain anomaly classification // *Cluster Computing*. – 2026. – Vol. 29. No. 3. – Art. No. 148. DOI: 10.1007/s10586-025-05893-x.
19. Zhou X., Wang H., Wang Z., Li X., Long Z. Anomaly Detection Method for High-Speed Maglev Train Suspension System Based on Isolation Forest and Improved LSTM // *IEEE Transactions on Transportation Electrification*. – 2026. – Vol. 12. No. 2. – pp. 3907–3919. DOI: 10.1109/TTE.2025.3645233.

References

1. Kuzmina A.O., Ilyina M.Yu., Lukichev K.E., Presnyakova N.G., Tatarnikov A.A. ATT-CNN mapping of the Udokan-type Cu-Mo porphyry deposits. *Mining Industry*. 2026. No. 1. pp. 135–142. DOI: 10.30686/1609-9192-2026-1-135-142. (In Russ.)
2. Shedko Yu.N., Kharchenko K.V., Zudenkova S.A., Galkin A.I., Babayan L.K. Deep Q-learning in traffic control of BelAZ mining dump trucks at the deposits of the Kursk Magnetic Anomaly. *Mining Industry*. 2026. No. 1. pp. 105–113. DOI: 10.30686/1609-9192-2026-1-105-113. (In Russ.)
3. Chen H., Wu G., Chen H., Xu C., Wu C. Modeling of high-precision sea surface geomagnetic field in the Northern South China Sea Based on PSO-BP neural network. *Journal of Marine Science and Engineering*. 2026. Vol. 14. No. 1. Art. No. 108. DOI: 10.3390/jmse14010108.
4. Fan L., Lin G., Zheng Q., Ni F. Condition monitoring of levitation systems for maglev trains using Bayesian physics-informed neural networks. *Measurement Science and Technology*. 2026. Vol. 37. No. 2. Art. No. 026109. DOI: 10.1088/1361-6501/ae26a7.
5. Ghamizi S., Kanli G., Deng Y., Palissot V., Perquin M., Keunen O. Foundation models for brain imaging: A systematic review. *NeuroImage*. 2026. Vol. 333. Art. No. 121877. DOI: 10.1016/j.neuroimage.2026.121877.
6. Ghosh J., Thoram S., Sun J., Sager W.W. Enhancing marine magnetic anomaly interpretation with anisotropic diffusion and deep transfer learning. *Scientific Reports*. 2026. Vol. 16. No. 1. Art. No. 1185. DOI: 10.1038/s41598-025-30926-1.
7. Hui R., Liang X., Zuo C., Wang Z. 2D CNN based multifeature fusion detection method for the magnetic anomaly generated by submarine wake. *Journal of Ocean Engineering and Science*. 2025. Vol. 10. No. 6. pp. 1139–1154. DOI: 10.1016/j.joes.2023.11.001.
8. Li Q., Li Z., Wang Z., Lang Y., Liu H., Zhao W. et al. Optical fiber sensor based transportable active seismic survey system solution to OSI. *Pure and Applied Geophysics*. 2025. Vol. 182. No. 12. pp. 5303–5313. DOI: 10.1007/s00024-024-03539-4.
9. Ma L., Wang J. High-precision delineation of curie point depth under remanent magnetization using physics-informed neural networks. *Geophysical Research Letters*. 2026. Vol. 53. No. 7. Art. No. e2025GL120275. DOI: 10.1029/2025GL120275.
10. Rahmaniar W., Suzuki K. Multi-AD: cross-domain unsupervised anomaly detection for medical and industrial applications. *Pattern Recognition*. 2026. Vol. 172. Art. No. 112486. DOI: 10.1016/j.patcog.2025.112486.
11. Shen J., Hou Z., Wei J., Zhao X., Wang J. SDCNet: Stable downward continuation of magnetic anomalies by depth information fusion. *IEEE Geoscience and Remote Sensing Letters*. 2026. Vol. 23. Art. No. 7501505. DOI: 10.1109/LGRS.2026.3657949.
12. Teknik V. Physics-informed neural networks for super-resolution of geospatial data: a case study from the aeromagnetic data of Central Iranian Plateau. *Geophysical Prospecting*. 2026. Vol. 74. No. 4. Art. No. e70175. DOI: 10.1111/1365-2478.70175.
13. Tyagi C., Ansari M.A., Usmani H., Yadav R.K. Recent trends of CNN in medical imaging: a comprehensive analysis. In: *Proceedings of the 2nd International Conference on Cognitive Computing in Engineering, Communications, Sciences and Biomedical Health Informatics (IC3ECSBHI 2026)*. Greater Noida, India. 2026. pp. 1625–1630. DOI: 10.1109/IC3ECSBHI67834.2026.11469172.
14. Wang Y.-L., Li C.-S., Zhang H., Wang X.-F. Research on a rapid prediction method for magnetic anomaly responses in the penetration process based on an improved proper orthogonal decomposition (POD)-radial basis function (RBF) neural network. *Measurement*. 2025. Vol. 256. Art. No. 118266. DOI: 10.1016/j.measurement.2025.118266.
15. Wang H., Jiang C., Ren Y., Ding L. Research on magnetic anomaly signal detection based on CNN-LSTM. *Measurement Science and Technology*. 2026a. Vol. 37. No. 12. Art. No. 126111. DOI: 10.1088/1361-6501/ae5334.
16. Wang H., Tang Z., Qi X., Zhang D., Zhao C. A Magnetic anomaly inversion method integrating convolutional block attention module and physical consistency constraints. *Journal of Visualized Experiments*. 2026b. No. 229. Art. No. e69539. DOI: 10.3791/69539.

17. Ye J., Mansour A., Huang F. Enhancing real-time heading estimation for pedestrian navigation via deep learning and smartphone embedded sensors. *Scientific Reports*. 2025. Vol. 15. No. 1. Art. No. 31672. DOI: 10.1038/s41598-025-13390-9.

18. Yurtsever M.M.E., Eken S., Arslan B., Atay Y., Sagioglu S., Celtikci E. et al. Evaluating augmented deep networks for MRI-based brain anomaly classification. *Cluster Computing*. 2026. Vol. 29. No. 3. Art. No. 148. DOI: 10.1007/s10586-025-05893-x.

19. Zhou X., Wang H., Wang Z., Li X., Long Z. Anomaly Detection Method for High-Speed Maglev Train Suspension System Based on Isolation Forest and Improved LSTM. *IEEE Transactions on Transportation Electrification*. 2026. Vol. 12. No. 2. pp. 3907–3919. DOI: 10.1109/TTE.2025.3645233.