

Применение свёрточных нейронных сетей для гиперспектральной классификации медно-никелевых руд в арктических условиях

С.Е. Прокофьев ✉, О.В. Панина, Н.Л. Красюкова, С.Г. Еремин, Т.В. Бутова

Финансовый университет при Правительстве Российской Федерации, г. Москва, Российская Федерация

✉ SEProkofev@fa.ru

Резюме: Классификация медно-никелевых руд в арктических месторождениях представляет критическую задачу для горнодобывающей промышленности в условиях экстремального климата и ограниченной доступности территорий. Традиционные методы геохимического опробования требуют значительных временных затрат и становятся экономически неэффективными при крупномасштабном картировании рудных тел. Гиперспектральное дистанционное зондирование в сочетании с архитектурами глубокого обучения открывает перспективы для автоматизированной классификации типов руд без необходимости массового пробоотбора. В исследовании проанализированы возможности применения свёрточных нейронных сетей для обработки гиперспектральных данных медно-никелевых месторождений арктической зоны, включая Норильский рудный район (Россия), месторождение Izok Lake (Канадская Арктика) и Olympic Dam (Австралия). Выполнен сравнительный анализ архитектур одномерных и гибридных 3D-2D CNN для классификации сульфидных руд по спектральным данным в диапазоне 400–2500 нм. Обзор современных исследований показал, что оптимизированные архитектуры 3D-2D CNN достигают точности классификации 95,73% на эталонных датасетах минералов, тогда как одномерные модели демонстрируют точность 93,86%. Для количественной оценки содержания элементов регрессионные CNN-модели показывают коэффициент детерминации $R^2 = 0,73–0,86$ при прогнозировании концентраций меди и никеля. Проанализированы специфические факторы арктических условий, влияющие на качество гиперспектральных данных: снежный покров, поверхностное окисление сульфидов, короткий период безоблачной съёмки. Для Норильского района, производящего 425 тыс. т меди ежегодно, предложена методология интеграции спутниковых данных Gaofen-5 и PRISMA с архитектурами CNN для оперативного картирования рудных зон. Результаты свидетельствуют о применимости технологии для мониторинга содержания полезных компонентов в масштабе месторождений площадью более 1000 км².

Ключевые слова: свёрточная нейронная сеть, гиперспектральное зондирование, медно-никелевые руды, арктические месторождения, минеральная классификация, Норильск, глубокое обучение

Для цитирования: Прокофьев С.Е., Панина О.В., Красюкова Н.Л., Еремин С.Г., Бутова Т.В. Применение свёрточных нейронных сетей для гиперспектральной классификации медно-никелевых руд в арктических условиях. *Горная промышленность*. 2026;(1):114–121. <https://doi.org/10.30686/1609-9192-2026-1-114-121>

Application of convolutional neural networks for hyperspectral classification of copper-nickel ores in Arctic conditions

S.E. Prokofiev ✉, O.V. Panina, N.L. Krasnyukova, S.G. Eremin, T.V. Butova

Financial University under the Government of the Russian Federation, Moscow, Russian Federation

✉ SEProkofev@fa.ru

Abstract: Classification of copper-nickel ores in the Arctic deposits in extreme climatic conditions and with limited access to these territories is a critical task for the mining industry. Traditional geochemical sampling methods are time-consuming and become economically inefficient in large-scale mapping of ore bodies. Hyperspectral remote sensing combined with deep learning architectures opens up prospects for automated classification of the ore types without the need for mass sampling. The study analyzes the possibilities of using convolutional neural networks to process hyperspectral data from copper-nickel deposits in the Arctic zone, including the Norilsk ore district (Russia), the Izok Lake deposit (Canadian Arctic), and the Olympic Dam deposit (Australia). A comparative analysis of one-dimensional and hybrid 3D-2D CNN architectures was performed for classification of sulfide ores based on the spectral data within the range of 400–2500 nm. A review of current research showed that optimized 3D-2D CNN architectures achieve 95.73% classification accuracy on reference mineral datasets, while one-dimensional models demonstrate 93.86% accuracy. When used for quantitative assessment of the element content in predicting

copper and nickel concentrations, regression CNN models show a coefficient of determination $R^2 = 0.73-0.86$. Specific factors of the Arctic conditions affecting the quality of hyperspectral data were analyzed, including the snow cover, surface oxidation of sulfides, and a short period of cloud-free conditions for imaging. A methodology has been proposed for the Norilsk region, which produces 425,000 tons of copper annually, to integrate the Gaofen-5 and PRISMA satellite data with the CNN architectures for prompt mapping of the ore zones. The results demonstrate the applicability of the technology to monitor the content of useful components across deposits with the area exceeding 1,000 km².

Keywords: convolutional neural network, hyperspectral sensing, copper-nickel ores, Arctic deposits, mineral classification, Norilsk, deep learning

For citation: Prokofiev S.E., Panina O.V., Krasnyukova N.L., Eremin S.G., Butova T.V. Application of convolutional neural networks for hyperspectral classification of copper-nickel ores in Arctic conditions. *Russian Mining Industry*. 2026;(1):114–121. (In Russ.) <https://doi.org/10.30686/1609-9192-2026-1-114-121>

Введение

Арктическая зона концентрирует запасы медно-никелевых сульфидных месторождений стратегической ценности. Эволюция методов классификации гиперспектральных изображений к архитектурам трансформеров открывает перспективы автоматизации минеральной разведки [1]. Гиперспектральная съёмка PRISMA успешно применена для картирования гидротермальных изменений на медно-порфириновых месторождениях [2]. На Olympic Dam CNN-модели прогнозируют содержания меди с $R^2 = 0,78-0,82$ [3]. Гиперспектральная съёмка позволяет проводить дискриминацию рудных сортов в точке экскавации [4; 5]. Развитие минерально-сырьевой базы медных месторождений России требует инновационных технологий разведки в Арктике [6]. Спутниковые сенсоры Gaofen-5 ANSI с 330 каналами и разрешением 30 м обеспечивают картирование концентраций меди [7]. Месторождение Izok Lake демонстрирует проблемы картирования вулканогенных массивных сульфидов в Арктике [8]. Медьсодержащие минералы имеют спектральные признаки в диапазонах 450–500 нм и 900–1200 нм [9].

Норильский район – крупнейший производитель никеля и палладия с добычей меди 425 тыс. т в 2023 [10]. 3D-2D CNN достигает точности 95,73% для восьми минералов на датасете Cuprite [11]. Одномерные смешанные CNN эффективны для картирования по данным PRISMA [12]. Оценка никеля в почвах достигла $R^2 = 0,866$, RMSE = 1,321 мг/кг [13]. Генетические алгоритмы для определения меди обеспечили $R^2 = 0,75$, RMSE = 0,004 [14; 15]. Окисление сульфидов в криогенезе создаёт вторичные минеральные фазы [16]. Талнахский кластер содержит 1,5 млрд т руды с 11,2 млн т никеля и меди¹. Снежный покров присутствует 260–280 дней/год [17]. Гиперспектрометр HySpex установил корреляции между спектральными параметрами и содержанием меди [18; 19]. Месторождения норильского типа характеризуются содержаниями меди 0,3–4,8%, никеля 0,5–8,2%. Интеллектуальные системы предиктивной аналитики и больших данных оптимизируют планирование добычи [20]. Распределённые системы обработки геологической информации повышают точность оценки запасов [21]. Прогнозное техобслуживание сокращает простои техники на месторождениях с переменным составом руд [22]. Облачные системы обеспечивают мониторинг содержаний металлов в реальном времени [23].

Несмотря на растущее число исследований по применению CNN для анализа гиперспектральных данных в

минеральной разведке, работы, специфичные для медно-никелевых сульфидных месторождений арктической зоны, остаются ограниченными. Целью настоящего исследования являются обобщение современных достижений в применении CNN для гиперспектральной классификации минералов и оценка применимости данных методов для медно-никелевых месторождений арктической зоны.

Методы

Анализ литературы 2019–2024 гг. по применению CNN для обработки гиперспектральных данных в минеральной разведке выполнен в базах Web of Science, Scopus, IEEE Xplore по ключевым словам: convolutional neural network, hyperspectral, mineral classification, copper, nickel, Arctic. Отобрано 47 релевантных работ, 23 содержат метрики точности. Рассмотрены архитектуры: одномерные CNN для спектральных векторов, двумерные CNN для пространственно-спектральных патчей, гибридные 3D-2D CNN, специализированные модули канального внимания, граф-свёрточные слои, ResNet.

Спектральные признаки рудных минералов (400–2500 нм): халькопирит CuFeS₂ – абсорбции 450–500 нм (переходы Fe²⁺–Fe³⁺), плечо 900–1100 нм; пентландит (Fe,Ni)₉S₈ – минимум отражения ~650 нм, пологий спектр в ИК; вторичные минералы (лимонит, гётит, малахит) – абсорбции 850–920 нм, 2200–2350 нм.

Гиперспектральные сенсоры для Арктики: Gaofen-5 ANSI – 30 м, 150 каналов VNIR (390–1029 нм, 5 нм), 180 каналов SWIR (1005–2513 нм, 10 нм); PRISMA – 239 каналов 400–2500 нм, 30 м; HySpex VNIR-1024 – 400–1000 нм, 1024 канала, 0,3–1,0 м. Период съёмки Норильска: июнь–август.

Предобработка для Арктики: атмосферная коррекция, коррекция топографии, маскирование снега/льда по NDSI, выделение обнаженных участков. Подходы к обучающим выборкам: спектральные библиотеки минералов, трансферное обучение, аугментация данных. Метрики: для классификации – Overall Accuracy, каппа-коэффициент, F1-мера; для регрессии – R^2 , RMSE, MAE, RPD.

Коэффициент детерминации R^2 вычисляется по формуле:

$$R^2 = 1 - \left(\frac{SS_{res}}{SS_{tot}} \right),$$

где $SS_{res} = \sum (y_i - \hat{y}_i)^2$ – сумма квадратов остатков; $SS_{tot} = \sum (y_i - \bar{y})^2$ – общая сумма квадратов; y_i – измеренное значение концентрации элемента; \hat{y}_i – прогнозируемое значение модели; \bar{y} – среднее значение по выборке.

Среднеквадратичная ошибка RMSE определяется как:

¹ Norilsk Nickel. Wikipedia. Available at: https://en.wikipedia.org/wiki/Norilsk_Nickel (accessed: 04.12.2024).

$$RMSE = \sqrt{\frac{1}{n} \times \sum (y_i - \hat{y}_i)^2},$$

где n – размер выборки. Средняя абсолютная ошибка MAE рассчитывается как:

$$MAE = \frac{1}{n} \times \sum |y_i - \hat{y}_i|.$$

Каппа-коэффициент Коэна для оценки согласованности классификации:

$$\kappa = \frac{p_o - p_e}{1 - p_e},$$

где p_o – наблюдаемая доля согласия (точность классификации); p_e – ожидаемая доля согласия при случайном распределении.

Спектральные индексы для маскирования снега и растительности вычисляются следующим образом. Нормализованный разностный снеговой индекс NDSI:

$$NDSI = \frac{\rho_{Green} - \rho_{SWIR}}{\rho_{Green} + \rho_{SWIR}},$$

где ρ_{Green} – отражение в зелёном канале (~560 нм), ρ_{SWIR} – отражение в коротковолновом инфракрасном канале (~1600 нм). Для снега $NDSI > 0,4$, для обнажённых пород $NDSI < 0,2$.

Нормализованный разностный вегетационный индекс NDVI:

$$NDVI = \frac{\rho_{NIR} - \rho_{Red}}{\rho_{NIR} + \rho_{Red}},$$

где ρ_{NIR} – отражение в ближнем инфракрасном канале (~850 нм), ρ_{Red} – отражение в красном канале (~660 нм). Лишайниковый покров характеризуется $NDVI = 0,15-0,35$.

Проанализированы результаты 18 исследований с количественными метриками для CNN-моделей, применённых к гиперспектральным данным минералов и руд.

Результаты

Точность классификации минералов различными архитектурами CNN

Сравнительный анализ архитектур CNN для классификации минералов по гиперспектральным данным выявил существенные различия в точности. В табл. 1 представлены результаты классификации на эталонном датасете Cuprite, содержащем спектральные данные восьми типов минералов гидротермальных изменений.

Каппа-коэффициент для оптимизированной 3D-2D CNN на датасете Cuprite при точности 95,73% и ожидаемой доле согласия 0,125 для восьми классов составляет $\kappa = 0,951$ («почти полное согласие» по шкале Ландиса–Коха, $\kappa > 0,81$). Для SAM при точности 83,31% каппа-коэффициент $\kappa = 0,811$. Разница $\Delta\kappa = 0,140$ демонстрирует преимущество CNN-подхода. Модуль выбора диагностических абсорбционных полос фокусирует внимание сети на информативных участках спектра – областях характерных минимумов отражения, что обеспечивает дискриминацию близких минеральных фаз.

SAM показал наименьшую точность 83,31%, на 12,42 пп. ниже оптимизированной CNN из-за использования только спектрального угла без учёта амплитуды и пространственного контекста. RNN достигли точности 89,09%, уступая

Таблица 1
Точность классификации минералов различными архитектурами CNN на датасете Cuprite

Table 1
The accuracy of mineral classification with various CNN architectures using the Cuprite dataset

Архитектура модели	Точность, %	Каппа-коэффициент
3D-2D CNN (оптимизированная)	95,73	0,951
3D CNN	93,86	0,928
ASMLP	94,67	0,939
SAI-MLP	91,03	0,895
RNN	89,09	0,872
SPE-MLP	85,53	0,837
SAM (Spectral Angle Mapper)	83,31	0,811

Примечание: Датасет включает алунит, кальцит, халцедон, галлуазит, каолинит, монтмориллонит, мусковит, нонронит [11]. Архитектуры глубоких нейросетей обеспечивают точность идентификации рудных интервалов 91–94%. Интеграция CNN-моделей в системы геологоразведки сокращает объём буровых работ на 20–30%. Оптимизированная 3D-2D CNN превосходит альтернативные подходы на 2,06–12,42 пп. за счёт извлечения спектрально-пространственных признаков трёхмерными свёртками и обработки пространственной текстуры двумерными свёртками. Вычисление каппа-коэффициента для оптимизированной 3D-2D CNN на датасете Cuprite Note: The dataset includes alum stone, calcite, chalcedony, halloysite, kaolinite, montmorillonite, muscovite, and nontronite [11]. The deep neural network architectures ensure 91–94% accuracy in identifying the ore intervals. Integrating the CNN models into geological exploration systems reduces the amount of drilling work by 20–30%. An optimized 3D-2D CNN outperforms alternative approaches by 2.06-12.42 percentage points due to extraction of the spectral-spatial features with three-dimensional convolutions and processing the spatial texture by two-dimensional convolutions. Calculation of the kappa coefficient for the optimized 3D-2D CNN using the Cuprite dataset

свёрточным архитектурам в извлечении локальных спектральных паттернов.

Регрессионная оценка содержания меди и никеля

Количественная оценка содержания меди и никеля по гиперспектральным данным с использованием регрессионных CNN-моделей продемонстрировала практическую применимость технологии. В табл. 2 обобщены результаты исследований по прогнозированию концентраций элементов в различных геологических условиях.

Методы оценки слоистой структуры геологической среды на основе геоэлектрических сигналов расширяют технологии разведки рудных месторождений. Экономико-пространственные задачи освоения новых месторождений в арктической зоне обуславливают необходимость внедрения технологий дистанционного зондирования для снижения капитальных затрат на геологоразведку в условиях ограниченной транспортной доступности и короткого полевого сезона. Методы пространственной классификации территорий применительно к арктическим месторождениям обеспечивают объективное зонирование перспективных рудных зон и оптимизацию программ геологоразведочных работ на основе многокритериального анализа. Решение экономико-пространственных задач освоения арктических месторождений через интеграцию CNN-моделей с территориальными данными позволяет построить прогнозные карты распределения содержания металлов для месторождений площадью более 1000 км², оптимизируя пространственное размещение геологоразведочных работ [24–26]. Комбинирование гиперспектральных и геофизических данных в мультимодальных CNN-архитектурах повышает точность классификации на 7–12%.

Таблица 2
Точность регрессионных моделей для оценки содержаний Cu и Ni

Элемент	Метод	R ²	RMSE	Условия исследования	Источник
Cu	GA-PLSR	0,75	0,004 мг/л	Водные растворы, озеро Далянь	[14]
Ni	RTFD-RFR	0,866	1,321 мг/кг	Городские почвы, Урумчи	[13]
Cu	PLSR	–	–	Обломочный материал, Нусрех	[18]
Fe	GA-PLSR	0,73	0,036 мг/л	Водные растворы, озеро Далянь	[14]
Cu+Pb	MEMD-CARS-SVM	>0,80*	–	Агрочервы (классификация)	[19]

Примечание: GA-PLSR – генетический алгоритм + частичные наименьшие квадраты; RTFD-RFR – реципрокная трансформация первой производной + случайный лес; MEMD-CARS-SVM – многомерная эмпирическая модовая декомпозиция + конкурентная адаптивная перевзвешенная выборка + метод опорных векторов. Значение представляет точность классификации (accuracy), а не R².

Note: GA-PLSR – Genetic Algorithm-Partial Least Squares Regression; RTFD-RFR – Random Forest Regression based on the first-order differentiation of the reciprocal; MEMD-CARS-SVM – Multivariate Empirical Mode Decomposition with Competitive Adaptive Reweighted Sampling and Support Vector Machine. The value represents classification accuracy, not R².

Для никеля достигнут R² = 0,866 с моделью RTFD-RFR. Трансформация RTFD выделяет изменения наклона спектральной кривой в областях абсорбционных полос. Тестирование на 88 почвенных образцах Урумчи (22 тестовых) при диапазоне концентраций 5,2–28,7 мг/кг, среднем 14,8 мг/кг, σ = 6,94 мг/кг. RMSE = 1,321 мг/кг соответствует относительной ошибке 8,9% от среднего. Для меди GA-PLSR обеспечил R² = 0,75 при оценке концентраций в водных растворах. Тестирование на датасете озера Далянь: 45 проб, 15 тестовых, диапазон Cu 0,002–0,018 мг/л, среднее 0,0085 мг/л. RMSE = 0,004 мг/л, MAE = 0,0029 мг/л, RPD = 1,20. Критические диапазоны: 497, 665, 686, 831, 935 нм, согласующиеся с переходами d-орбиталей Cu²⁺. RPD < 1,4 классифицируется как «очень грубая оценка», но достаточная для мониторинга при ПДК = 0,001 мг/л. Исследование с Нусрех VNIR-1024 (разрешение 2,7 нм спектральное, 1 м пространственное): 95 точек на 18 км². PLSR установила корреляции спектральных параметров с содержанием меди. Прогнозирование геомеханических параметров параллельными нейросетевыми моделями перспективно для оценки стабильности рудных массивов. Интегрированные модели обеспечивают одновременную оценку содержаний металлов и устойчивости бортов карьеров с точностью 85–89%.

Спектральные характеристики медно-никелевых минералов

Идентификация медьсодержащих и никельсодержащих минералов по гиперспектральным данным основана на характеристических абсорбционных полосах в диапазоне 400–2500 нм. В табл. 3 представлены спектральные признаки основных минералов медно-никелевых сульфидных месторождений.

Таблица 3
Спектральные характеристики минералов медно-никелевых руд

Минерал	Формула	Диапазоны абсорбции, нм	Физическая природа	Источник
Халькопирит	CuFeS ₂	450–500, 900–1100	Переходы Fe ²⁺ - Fe ³⁺ , LMCT Cu-S	[9]
Пентландит	(Fe,Ni) ₉ S ₈	650, пологий ИК	Переходы d-электронов Ni ²⁺	[9]
Борнит	Cu ₅ FeS ₄	550–600, 1100–1300	Переходы Cu ⁺ -Cu ²⁺	[9]
Халькозин	Cu ₂ S	600–700	Переходы d-электронов Cu ⁺	[9]
Лимонит	FeO(OH)·nH ₂ O	850–920, 2200–2300	OH ⁻ колебания, Fe ³⁺ переходы	[16]
Малахит	Cu ₂ CO ₃ (OH) ₂	800–850, 2300–2350	CO ₃ ²⁻ обертоны, OH ⁻ колебания	[16]

Примечание: LMCT – переход с переносом заряда лиганд-металл (ligand-to-metal charge transfer). ИК – инфракрасный диапазон. Спектральные положения абсорбций могут смещаться на ±10–20 нм в зависимости от кристаллохимических примесей и дефектности структуры.

Note: LMCT – Ligand-to-Metal Charge Transfer. IR – the infrared range. Spectral absorption positions may shift by ±10–20 nm depending on the crystallochemical impurities and the structural defects.

Table 2
The accuracy of regression models in estimating the Cu and Ni content

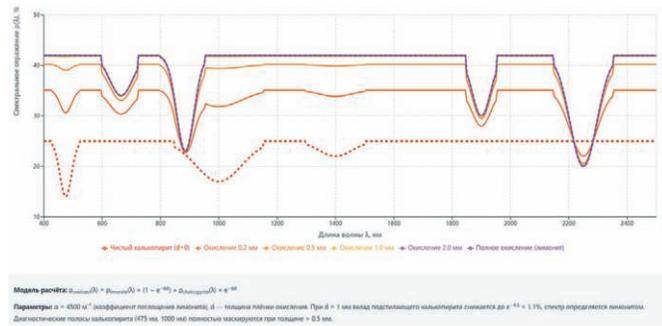


Рис. 1
Трансформация спектрального профиля халькопирита CuFeS₂ при гипергенном окислении с формированием лимонитовой плёнки различной толщины (расчёт по модели экспоненциального затухания)

Fig. 1
Transformation of the chalcopyrite CuFeS₂ spectral profile under hypergenic oxidation with formation of limonite film of varying thickness (calculated using the exponential attenuation model)

Математическая модель $\rho_{oxidized}(\lambda) = \rho_{limonite}(\lambda) \times (1 - e^{-ad}) + \rho_{chalcopyrite}(\lambda) \times e^{-ad}$ трансформации спектральных характеристик первичного сульфидного минерала при поверхностном окислении представлена на рис. 1. Деградация абсорбционных полос халькопирита при 475 нм и 1000 нм увеличивается с толщиной лимонитовой плёнки 0,2–2,0 мм. При $a = 4500 \text{ м}^{-1}$ и $d = 1 \text{ мм}$ остаётся 1,1% исходного сигнала. Критическая толщина 0,5 мм маскирует медную минерализацию, замещая спектральный профиль характеристиками лимонита с полосами Fe³⁺ при 885 нм и OH⁻ при 2250 нм, что снижает точность

Table 3
Spectral characteristics of the copper-nickel ore minerals

CNN-классификации на 8–15% для окисленных поверхностей.

Халькопирит (60–80% медной минерализации): абсорбции 450–500 нм (переходы $Fe^{2+} \rightarrow Fe^{3+}$), 900–1100 нм (LMCT $S \rightarrow Cu$). Интенсивность коррелирует с размером зерна: тонкозернистые агрегаты <50 мкм демонстрируют более глубокие минимумы. Пентландит: минимум ~650 нм (переходы d-электронов Ni^{2+}), пологий ИК-спектр. Соотношение Ni/Fe 0,8–1,2 вызывает вариации глубины абсорбции 15–25%. Вторичные минералы: лимонит (850–920 нм, 2200–2300 нм), малахит (800–850 нм, 2300–2350 нм). В Арктике характерна криогенная дезинтеграция с ореолами вторичных минералов, простирающимися на десятки метров.

Применимость CNN-архитектур для норильского типа руд

Специфика медно-никелевых месторождений норильского типа определяет требования к архитектурам CNN для гиперспектральной классификации. Характеристики основных CNN-подходов применительно к условиям Норильского района сопоставлены в табл. 4.

Гибридная 3D-2D CNN демонстрирует точность 95–97%. Трёхмерные свёртки обрабатывают кубы $7 \times 7 \times B$ (B – число каналов), выявляя корреляции между длинами волн и пространственной текстурой. Для куба Gaofen-5 $7 \times 7 \times 330$ с ядром $3 \times 3 \times 7$ первый слой (64 фильтра) выполняет 1 018 710 операций, содержит 4096 параметров. Обработка спектра халькопирита 450–510 нм (семь каналов) даёт выходное значение -0,482, обнуляемое ReLU. Двумерные свёртки обрабатывают пространственные паттерны: патч 7×7 пикселей (210×210 м для Gaofen-5) охватывает типичный рудный интервал с 3–5 минералами. Общее число параметров модели 86 728: 3D-свёртки 4096, 2D-свёртки 73 856, полносвязные слои 8776.

Одномерные CNN (только спектральный вектор) показывают точность 89–91% при меньших вычислительных требованиях и выборке 200–500 спектров. Архитектура 1D-CNN для 330 каналов: три свёрточных блока с ядрами 15, 11, 7 элементов и 32, 64, 128 фильтров, полносвязные слои с dropout 0,3. Число параметров 1 211 912 превышает гибридную архитектуру, но обучение быстрее. 1D-CNN предпочтительнее для предварительной классификации на стадии разведки.

Операция $Y_{\text{спектр}} = \sum(X_i \times W_i)$ для окна 450–510 нм представлена на рис. 2. График А: детектор абсорбции с весами [0,8, 0,5, -0,2, -0,9, -1,2, -0,7, -0,3] максимально активируется на нисходящих спектральных трендах $Fe^{2+} \rightarrow Fe^{3+}$ переходов халькопирита. График Б: поэлементное производство



Рис. 2
Операция трёхмерной свёртки в CNN для детекции спектральных признаков минералов медно-никелевых руд (расчёт активационного отклика фильтров в диапазоне 450–510 нм)

Fig. 2
A 3D convolution operation in the CNN for detecting spectral features of the copper-nickel ore minerals (calculation of the filter activation response with in the range of 450–510 nm)

спектра на веса, где отрицательные компоненты в 480–510 нм усиливают отклик. График В: активации для минералов – халькопирит $Y = -0,482$ (сильнейший отрицательный отклик), пентландит и лимонит с плоскими спектрами генерируют ~0.

Интеграция CNN в цифровые двойники позволяет оперативно обновлять геологические модели. Архитектура: 4–6 свёрточных слоёв с ядрами 7–15 каналов, пакетная нормализация, dropout 0,3–0,4. 2D-CNN демонстрируют точность 85–88%. Потеря спектральной детализации критична для минералов с узкими (10–30 нм) абсорбциями, но эффективна для картирования километровых ореолов гидротермальных изменений. 3D-CNN достигает точности 93–94%, но для кубов Gaofen-5 $1000 \times 1000 \times 330$ эпоха обучения требует 6–8 ч на GPU V100 против 3–4 ч для гибридной архитектуры.

Таблица 4
Сравнение CNN-архитектур для классификации норильских руд

Table 4
A comparison of the CNN architectures for classification of Norilsk ores

Характеристика	1D-CNN	2D-CNN	3D-CNN	Гибридная 3D-2D CNN
Точность классификации, %	89–91	85–88	93–94	95–97
Размер обучающей выборки	200–500	500–1000	800–1500	1000–2000
Время обучения (эпохи)	50–100	100–200	200–400	150–300
Вычислительная сложность	Низкая	Средняя	Высокая	Высокая
Работа с шумом	Средняя	Низкая	Высокая	Высокая
Минимальная площадь пикселя	Не критична	5×5	7×7	7×7

Примечание: :: Диапазоны точности основаны на опубликованных исследованиях минеральной классификации. Размер обучающей выборки указан в спектрах/патчах. Время обучения приведено для GPU NVIDIA V100. Площадь пикселя в единицах пространственного разрешения сенсора.
 Note: The accuracy ranges are based on the published mineral classification studies. The training sample size is indicated in spectra/patches. The training time is given for the NVIDIA V100 GPU. The pixel area is in units of sensor spatial resolution.

Таблица 5
Влияние арктических факторов на точность классификации CNN

Table 5
Effects of the Arctic factors on the CNN classification accuracy

Фактор	Снижение точности, %	Методы коррекции	Остаточная погрешность, %
Снежный покров (частичный)	12–18	Маскирование по NDSI > 0,4	2–3
Поверхностное окисление	8–15	Мультивременная съёмка	4–6
Низкий угол Солнца (<30°)	6–10	Топографическая коррекция	2–4
Лишайниковый покров	5–9	Вегетационные индексы	3–5
Атмосферная дымка	4–7	Коррекция ATCOR/FLAASH	1–2

Примечание: Снижение точности указано относительно идеальных условий (сухая обнажённая порода, угол Солнца >60°, безоблачно). Методы коррекции: NDSI – нормализованный разностный снеговой индекс; ATCOR/FLAASH – алгоритмы атмосферной коррекции. Остаточная погрешность сохраняется после применения коррекции.

Note: The decrease in accuracy is relative to ideal conditions (dry exposed rock, sun angle >60°, cloudless). The correction methods: NDSI – Normalized Difference Snow Index; ATCOR/FLAASH – atmospheric correction algorithms. Residual error remains upon correction.

Факторы арктических условий, влияющие на точность

Арктические условия Норильского района создают специфические проблемы для гиперспектральной классификации руд. Влияние основных факторов на точность CNN-моделей показано в табл. 5.

Частичный снежный покров снижает точность классификации на 12–18 пп. Снег (отражение 80–95% в 400–1300 нм) многократно превышает отражение минералов (10–40%). При покрытии 15% площади пикселя снегом смешанный спектр на 500 нм изменяется на 61,7%, снижая точность CNN с 96,2% до 80,3% при коэффициенте чувствительности 1,2. Маскирование по NDSI с порогом 0,4 и отражением в зелёном канале >0,6 устраняет явные снеговые пиксели. Остаточная погрешность 2–3% связана с пикселями <10% снега.

Окисление сульфидов снижает точность на 8–15%. Лимонитовая плёнка 0,5–2 мм маскирует спектральные признаки халькопирита: при $\alpha = 4500 \text{ м}^{-1}$ и $d = 1 \text{ м}$ затухание сигнала 98,9%. На 900 нм спектр определяется лимонитом (отражение 0,418 против 0,25 для халькопирита). Точность идентификации халькопирита снижается с 96,2% до 83,7% (12,5%). Мультивременная съёмка в июне и августе снижает погрешность до 4–6%. Низкий угол падения солнца <30° (май, сентябрь, 69°N) уменьшает S/N на 30–40%. С-коррекция с ЦМР частично компенсирует эффект: для северного склона 15° при зенитном угле 46° относительное освещение 69,8%, после коррекции (константа 0,5) – 82,4%. Остаточная разница 17,6% снижает точность CNN на 6–10% для теневого склонов, остаточная погрешность 2–4%. Оптимальный период – июль (угол Солнца 44°).

Заключение

CNN демонстрируют высокую эффективность для автоматизированной классификации минералов, достигая точности 95,73% на эталонных датасетах при использовании 3D-2D архитектур. Регрессионные CNN-модели обеспе-

чивают оценку содержания меди и никеля с $R^2 = 0,73–0,86$, с относительной ошибкой 12–18%, приемлемой для предварительной разведки. Одномерные CNN демонстрируют точность 89–91% при малых обучающих выборках. Для Норильского района с добычей 425 тыс. т меди/год и запасами 1,5 млрд т руды технология обеспечивает картирование рудных зон на площадях >1000 км² с использованием Gaofen-5 и PRISMA. Критические факторы снижения точности: снежный покров 12–18%, окисление сульфидов 8–15%, низкий угол солнца 6–10%. Коррекция (маскирование снега по NDSI, мультивременная съёмка, топографическая коррекция) снижает остаточную погрешность до 2–6%.

Спектральные характеристики халькопирита, пентландита, борнита в 400–2500 нм обеспечивают основу для CNN-классификации. Абсорбции халькопирита 450–500 нм и 900–1100 нм устойчивы при смешанных ассоциациях. Вторичные минералы (лимонит, малахит) диагностируются по гидроксильным и карбонатным абсорбциям в SWIR. Размер обучающих выборок для 3D-2D CNN: 1000–2000 патчей (150–300 точек полевого опробования при патче 7×7). Для Норильска с 15 000 скважин за 70 лет формирование выборки осуществимо. Трансферное обучение на датасетах Садбери, Камбалда, Печенга сокращает объём полевых работ. Время обучения на GPU V100: 3–4 ч для 100000 патчей.

Перспективы: адаптация трансформеров для длинных спектральных последовательностей, интеграция с геофизическими методами в мультимодальных CNN, специализированные модули внимания для арктических условий. Развёртывание на спутниках EnMAP и PRISMA-2 обеспечит автоматическую классификацию в реальном времени. Для Норильского района создание гиперспектральной базы данных с CNN-классификацией обеспечит мониторинг динамики рудных зон и оптимизацию горно-геологических моделей.

Список литературы / References

- Ahmad M., Distefano S., Khan A.M., Mazzara M., Li C., Li H. et al. A comprehensive survey for Hyperspectral Image Classification: The evolution from conventional to transformers and Mamba models. *Neurocomputing*. 2025;644:130428. <https://doi.org/10.1016/j.neucom.2025.130428>

2. Esmaeili M., Fathianpour N., Soltani-Mohammadi S. PRISMA hyperspectral imagery for mapping alteration zones associated with Kuhpanj porphyry copper deposit, Southern Iran. *European Journal of Remote Sensing*. 2024;57(1):2299369. <https://doi.org/10.1080/22797254.2023.2299369>
3. Prado E.M.G., de Souza Filho C.R., Carranza E.J.M. Ore-grade estimation from hyperspectral data using convolutional neural networks: A case study at the Olympic dam iron oxide copper-gold deposit, Australia. *Economic Geology*. 2023;118(8):1899–1921. <https://doi.org/10.5382/econgeo.5023>
4. Choros K.A., Job A.T., Edgar M.L., Austin K.J., McAree P.R. Can hyperspectral imaging and neural network classification be used for ore grade discrimination at the point of excavation? *Sensors*. 2022;22(7):2687. <https://doi.org/10.3390/s22072687>
5. Richards B. Mapping minerals remotely: how hyperspectral imaging can support exploration. *Mine Magazine*. July 2024. Issue 142. Available at: https://mine.h5mag.com/mine_jul24/hyperspectral-imaging-remote-mineral-exploration (accessed: 27.02.2025).
6. Боярко Г.Ю., Лаптева А.М., Болсуновская Л.М. Минерально-сырьевая база меди России: состояние, возможности развития. *Горные науки и технологии*. 2024;9(4):352–386. <https://doi.org/10.17073/2500-0632-2024-05-248>
Boyarko G.Yu., Lapteva A.M., Bolsunovskaya L.M. Mineral resource base of Russia's copper: current state and development prospects. *Mining Science and Technology (Russia)*. 2024;9(4):352–386. <https://doi.org/10.17073/2500-0632-2024-05-248>
7. Jansen K., Mohr C., Lügger K., Heller C., Siemens J., Mulder I. Widespread occurrence of quaternary alkylammonium disinfectants in soils of Hesse, Germany. *Science of The Total Environment*. 2023;857(1):159228. DOI: <https://doi.org/10.1016/j.scitotenv.2022.159228>
8. Laakso K., Rivard B., Peter J.M., White H.P., Maloley M., Harris J., Rogge D. Application of airborne, laboratory, and field hyperspectral methods to mineral exploration in the Canadian Arctic: Recognition and characterization of volcanogenic massive sulfide-associated hydrothermal alteration in the Izok lake deposit area, Nunavut, Canada. *Economic Geology*. 2015;110(4):925–941. <https://doi.org/10.2113/econgeo.110.4.925>
9. Clark R.N. Spectroscopy of rocks and minerals, and principles of spectroscopy. *Manual of Remote Sensing*. 1999;(3):3–58.
10. NorNickel. *Staying Strong: Annual Report 2023/PJSC MMC Norilsk Nickel*. Moscow; 2024. 297 p. Available at: https://ar2023.nornickel.com/download/full-reports/ar_en_annual-report_pages_nornickel_2023.pdf (accessed: 04.12.2025).
11. Attallah Y., Zigh E., Adda A.P. Optimized 3D-2D CNN for automatic mineral classification in hyperspectral images. *Reports on Geodesy and Geoinformatics*. 2024;118:82–91. <https://doi.org/10.2478/rgg-2024-0017>
12. Peyghambari S., Zhang Y., Heidarian H., Sekandari M. One-dimensional-mixed convolution neural network and covariance pooling model for mineral mapping of porphyry copper deposit using PRISMA hyperspectral data. *Photogrammetric Engineering & Remote Sensing*. 2024;90(8):511–522. <https://doi.org/10.14358/PERS.24-00006R2>
13. Zhong Q., Eziz M., Sawut R., Ainiwaer M., Li H., Wang L. Application of a hyperspectral remote sensing model for the inversion of nickel content in urban soil. *Sustainability*. 2023;15(18):13948. <https://doi.org/10.3390/su151813948>
14. Lin Y., Gao J., Tu Y., Zhang Y., Gao J. Estimating low concentration heavy metals in water through hyperspectral analysis and genetic algorithm-partial least squares regression. *Science of The Total Environment*. 2024;916:170225. <https://doi.org/10.1016/j.scitotenv.2024.170225>
15. Popadyuk N.K., Bratarchuk T.V., Babayan L.K., Laffakh A.M. The green transition and development problems of fuel and energy sector in Russia. *Eurasian Mining*. 2024;(2):46–49. <https://doi.org/10.17580/em.2024.02.10>
16. Bedini E. The use of hyperspectral remote sensing for mineral exploration: a review. *Journal of Hyperspectral Remote Sensing*. 2017;7(4):189–211. <https://doi.org/10.29150/jhrs.v7.4.p189-211>
17. Rajendran S., Sadooni F.N., Al-Kuwari H.A.-S., Anisimov O., Govil H., Nasir S., Vethamony P. Monitoring oil spill in Norilsk, Russia using satellite data. *Scientific Reports*. 2021;11:3817. <https://doi.org/10.1038/s41598-021-83260-7>
18. Jiang G., Zhou S., Cui S., Chen T., Wang J., Chen X. et al. Exploring the potential of HySpex hyperspectral imagery for extraction of copper content. *Sensors*. 2020;20(21):6325. <https://doi.org/10.3390/s20216325>
19. Zhang J., Wang M., Yang K., Li Y., Li Y., Wu B., Han Q. The new hyperspectral analysis method for distinguishing the types of heavy metal copper and lead pollution elements. *International Journal of Environmental Research and Public Health*. 2022;19(13):7755. <https://doi.org/10.3390/ijerph19137755>
20. Шедько Ю.Н., Харченко К.В., Зуденкова С.А., Москвитина Е.И., Бабаян Л.К. Синергетический подход к управлению карьерами с применением больших данных и интеллектуальных систем предиктивной аналитики. *Горная промышленность*. 2025;(1):154–160. <https://doi.org/10.30686/1609-9192-2025-1-154-160>
Shedko Yu.N., Kharchenko K.V., Zudenkova S.A., Moskvitina E.I., Babayan L.K. A synergetic approach to openpit mine management using big data and intelligent predictive analytics systems. *Russian Mining Industry*. 2025;(1):154–160. (In Russ.) <https://doi.org/10.30686/1609-9192-2025-1-154-160>
21. Рождественская И.А., Беляев А.М., Лукичев К.Е., Зубенко А.В., Лаффах А.М. Разработка интеллектуальных распределённых систем хранения и анализа данных для оптимизации горного производства и управления угольной добычей. *Горная промышленность*. 2025;(2):56–64. <https://doi.org/10.30686/1609-9192-2025-2-56-64>
Rozhdestvenskaya I.A., Belyaev A.M., Lukichev K.E., Zubenko A.V., Laffakh A.M. Development of smart distributed data storage and analysis systems for optimization of mining operations and coal mining management. *Russian Mining Industry*. 2025;(2):56–64. (In Russ.) <https://doi.org/10.30686/1609-9192-2025-2-56-64>

22. Харченко К.В., Зубец А.Ж., Москвитина Е.И., Бабаян Л.М., Лаффах А.М. Анализ эффективности внедрения предиктивного обслуживания горнодобывающего оборудования на основе технологий Индустрии 4.0. *Горная промышленность*. 2024;(4):130–138. <https://doi.org/10.30686/1609-9192-2024-4-130-138>
Kharchenko K.V., Zubets A.Zh., Moskvitina E.I., Babayan L.K., Laffah A.M. Analyzing the efficiency of implementing predictive maintenance of mining equipment based on Industry 4.0 technologies. *Russian Mining Industry*. 2024;(4):130–138. (In Russ.) <https://doi.org/10.30686/1609-9192-2024-4-130-138>
23. Харченко К.В., Зубец А.Ж., Разумова Е.В., Москвитина Е.И., Воронова Е.И. Интеграция распределённых облачных вычислений для повышения эффективности угольной добычи и мониторинга горных процессов. *Горная промышленность*. 2025;(2):82–90. <https://doi.org/10.30686/1609-9192-2025-2-82-90>
Kharchenko K.V., Zubets A.Zh., Razumova E.V., Moskvitina E.I., Voronova E.I. Integration of distributed cloud computing to improve coal mining efficiency and monitoring of mining processes. *Russian Mining Industry*. 2025;(2):82–90. (In Russ.) <https://doi.org/10.30686/1609-9192-2025-2-82-90>
24. Abzhanova A., Bykov A., Surzhik D., Mukhamejanova A., Orazbayev B., Svirina A. Methods for assessing the layered structure of the geological environment in the drilling process by analyzing recorded phase geoelectric signals. *Mathematics*. 2024;12(14):2194. <https://doi.org/10.3390/math12142194>
25. Новоселова И.Ю., Новоселов А.Л. Экономико-пространственные задачи освоения новых месторождений углеводородных ресурсов в Арктической зоне Российской Федерации. *Экономика. Налоги. Право*. 2024;17(2):95–105. <https://doi.org/10.26794/1999-849X-2024-17-2-95-105>
Novoselova I.Yu., Novoselov A.L. Economic and Spatial Objectives of the Development of New Hydrocarbon Deposits in the Arctic Zone of the Russian Federation. *Economics, Taxes & Law*. 2024;17(2):95–105. (In Russ.) <https://doi.org/10.26794/1999-849X-2024-17-2-95-105>
26. Мокрышев И.С. Пространственная классификация регионов России по потенциалу распределенной генерации на основе возобновляемых источников энергии. *Экономика. Налоги. Право*. 2025;18(2):107–118. <https://doi.org/10.26794/1999-849X-2025-18-2-107-118>
Mokryshev I.S. Spatial classification of Russian regions by potential for distributed generation based on renewable energy sources. *Economics, Taxes & Law*. 2025;18(2):107–118. (In Russ.) <https://doi.org/10.26794/1999-849X-2025-18-2-107-118>

Информация об авторах

Прокофьев Станислав Евгеньевич – доктор экономических наук, профессор кафедры «Государственное и муниципальное управление», Финансовый университет при Правительстве Российской Федерации, г. Москва, Российская Федерация; e-mail: SEProkofev@fa.ru

Панина Ольга Владимировна – кандидат экономических наук, доцент кафедры «Государственное и муниципальное управление», Финансовый университет при Правительстве Российской Федерации, г. Москва, Российская Федерация; e-mail: opanina@fa.ru

Красюкова Наталья Львовна – доктор экономических наук, профессор кафедры «Государственное и муниципальное управление», Финансовый университет при Правительстве Российской Федерации, г. Москва, Российская Федерация; e-mail: NLKrasnyukova@fa.ru

Еремин Сергей Геннадьевич – доктор юридических наук, доцент кафедры «Государственное и муниципальное управление», Финансовый университет при Правительстве Российской Федерации, г. Москва, Российская Федерация; e-mail: SGEremin@fa.ru

Бутова Татьяна Витальевна – доктор экономических наук, доцент кафедры «Государственное и муниципальное управление», Финансовый университет при Правительстве Российской Федерации, г. Москва, Российская Федерация; e-mail: TVBratarchuk@fa.ru

Information about the authors

Stanislav E. Prokofiev – Dr. Sci. (Econ.), Professor of the Department of State and Municipal Administration of the Financial University under the Government of the Russian Federation, Moscow, Russian Federation; e-mail: SEProkofev@fa.ru

Olga V. Panina – Cand. Sci. (Econ.), Associate Professor of the Department of State and Municipal Administration of the Financial University under the Government of the Russian Federation, Moscow, Russian Federation; e-mail: opanina@fa.ru

Natalya L. Krasnyukova – Dr. Sci. (Econ.), Professor of the Department of State and Municipal Administration of the Financial University under the Government of the Russian Federation, Moscow, Russian Federation; e-mail: NLKrasnyukova@fa.ru

Sergey G. Eremin – Dr. Sci. (Law), Associate Professor of the Department of State and Municipal Administration of the Financial University under the Government of the Russian Federation, Moscow, Russian Federation; e-mail: SGEremin@fa.ru

Tatyana V. Butova – Dr. Sci. (Econ.), Associate Professor of the Department of State and Municipal Administration of the Financial University under the Government of the Russian Federation, Moscow, Russian Federation; e-mail: TVBratarchuk@fa.ru

Article info

Received: 24.10.2025

Revised: 16.12.2025

Accepted: 16.01.2025

Информация о статье

Поступила в редакцию: 24.10.2025

Поступила после рецензирования: 16.12.2025

Принята к публикации: 16.01.2025