

Нейросетевая обработка данных рентгенофлуоресцентного анализа для экспресс-оценки качества железорудного концентрата

Ю.С. Бузыкова ✉

Финансовый университет при Правительстве Российской Федерации, г. Москва, Российская Федерация
✉ juliaserg_buz@mail.ru

Резюме: Массовая доля железа и содержание основных примесей (SiO_2 , Al_2O_3 , P, S) определяют как металлургическую ценность, так и рыночную стоимость железорудного концентрата, а требование «доменного» сырья с $\text{Fe} > 69,5\%$ и $\text{SiO}_2 < 3\%$ диктует всё более жёсткие допуски по точности и оперативности контроля. Лабораторный рентгенофлуоресцентный анализ, основанный на фундаментальных параметрах и калибровке по стандартным образцам, обеспечивает приемлемую точность, однако при типовом времени обработки 15–40 мин на пробу перестаёт успевать за темпом современных обогатительных фабрик с часовой производительностью 3,5–4,8 тыс. т концентрата. Настоящая работа посвящена нейросетевой обработке первичных спектров рентгенофлуоресцентного анализа для экспресс-прогнозирования качества концентрата в режиме, сопоставимом с частотой технологических корректировок флотационной и магнитной схем. В основу положена выборка из 2140 парных наблюдений «спектр рентгенофлуоресцентного анализа – аттестованный химический анализ», собранных в сентябре 2024 – октябре 2025 г. на трёх обогатительных производствах Курской магнитной аномалии и сопоставимых по минералогическому составу образцах. Сопоставлены пять моделей: базовая PLS-регрессия, градиентный бустинг, одномерная свёрточная нейронная сеть (1D-CNN), остаточная сеть ResNet-1D и гибридная архитектура с механизмом внимания по спектральным каналам. Наилучший результат по массовой доле Fe достигнут гибридной моделью: $\text{RMSE} = 0,17\%$, $\text{MAE} = 0,12\%$, $R^2 = 0,987$; по SiO_2 – $\text{RMSE} = 0,24\%$; время обработки одного спектра – 14 мс на GPU и 92 мс на CPU, что на два порядка меньше лабораторной процедуры. Расчёт годового экономического эффекта для обогатительной фабрики производительностью 15 млн т концентрата даёт сокращение операционных расходов на 38–52 млн руб. и прирост выручки за счёт стабилизации Fe в пределах $\pm 0,2\%$ на 310–470 млн руб. в ценах 2025 г. Полученные результаты подтверждают жизнеспособность нейросетевой экспресс-оценки качества как элемента цифрового контура обогатительной фабрики.

Ключевые слова: рентгенофлуоресцентный анализ, нейронная сеть, железорудный концентрат, экспресс-оценка качества, свёрточные сети, цифровизация обогащения, механизм внимания, обогатительная фабрика

Для цитирования: Бузыкова Ю.С. Нейросетевая обработка данных рентгенофлуоресцентного анализа для экспресс-оценки качества железорудного концентрата. *Горная промышленность*. 2026;(3):217–225. <https://doi.org/10.30686/1609-9192-2026-3-217-225>

Processing of X-Ray fluorescence data with neural networks for express assessment of iron ore concentrate quality

Yu.S. Buzykova ✉

Financial University under the Government of the Russian Federation, Moscow, Russian Federation
✉ juliaserg_buz@mail.ru

Abstract: The iron mass fraction together with silica, alumina, phosphorus and sulphur contents govern both the metallurgical value and the market price of iron ore concentrates, while the requirements of the blast-furnace-grade feed with $\text{Fe} > 69.5\%$ and $\text{SiO}_2 < 3\%$ tightens the tolerances on analytical accuracy and response time. The laboratory X-ray fluorescence (XRF) analysis based on fundamental parameters and certified reference material calibration delivers adequate precision, however its 15 to 40 minute turnaround time per sample can no longer keep up with modern processing plants with the output from 3.5 to 4.8 thousand tonnes of concentrate per hour. This study addresses neural network processing of raw XRF spectra for express quality prediction at the frequency compatible with the flotation and magnetic separation control loops. A set of 2140 paired observations matching the raw XRF spectra with the certified wet chemical testing was collected between September 2024 and

October 2025 at three processing plants at the Kursk Magnetic Anomaly using mineralogically matching samples. Five models are benchmarked: a baseline PLS regression, gradient boosting, a one-dimensional convolutional neural network, a 1D residual network and a hybrid architecture with channel-wise attention over the spectrum. The hybrid model is the most accurate in terms of the Fe mass fraction, reaching RMSE = 0.17%, MAE = 0.12% and $R^2 = 0.987$; SiO₂ yields RMSE = 0.24%; inference time is 14 ms per spectrum using GPU and 92 ms using CPU, two orders of magnitude faster than the laboratory workflow. A calculation of the annual benefit for a plant producing 15 million tonnes of concentrate gives the operating cost savings of 38 to 52 million roubles and an additional revenue contribution of 310 to 470 million roubles through tighter Fe stabilization within $\pm 0.2\%$, in 2025 prices. The results confirm that express quality assessment using neural network is a viable element in the digital control envelope of a modern iron ore processing plant.

Keywords: X-ray fluorescence, neural network, iron ore concentrate, express quality assessment, convolutional networks, beneficiation digitalization, attention mechanism, processing plant

For citation: Buzykova Yu.S. Processing of X-Ray fluorescence data with neural networks for express assessment of iron ore concentrate quality. *Russian Mining Industry*. 2026;(3):217–225. (In Russ.) <https://doi.org/10.30686/1609-9192-2026-3-217-225>

Введение

Железорудное сырьё остаётся стержневым видом экспортной и внутренней металлургической продукции Российской Федерации: в 2024 г. отечественные комбинаты выпустили порядка 90,6 млн т концентрата при средней оптовой цене 7905,8 руб/т против 5628,6 руб/т двумя годами ранее. Ключевые игроки рынка – обогатительные производства Курской магнитной аномалии (КМА) Лебединский ГОК (ЛГОК) и Михайловский ГОК (МГОК) – уверенно закрепились в сегменте «премиум»: на ЛГОКе массовая доля железа в товарном концентрате достигает 69,5–70%, на МГОКе после ввода корпуса дообогащения в 2022 г. – до 71% Fe при SiO₂ не выше 1,5%. Любопытно, что именно эти полпроцента железа, отделяющие рядовой концентрат от DR-grade, и формируют более 35% премии в цене сырья для прямого восстановления.

Отсюда и практический запрос: контроль качества концентрата должен быть не только точным, но и быстрым. Классический рентгенофлуоресцентный анализ (РФА) по прессованным таблеткам или сплавленным стёклам обеспечивает высокую повторяемость (относительное стандартное отклонение 0,3–0,6% по Fe), однако полный цикл пробоподготовки, измерения и пересчёта по фундаментальным параметрам занимает, как правило, от 15 до 40 мин. Для фабрики с часовой производительностью 3,5–4,8 тыс. т это означает: к моменту получения результата под управление попадает партия объёмом 900–3200 т, и рычаги корректировки флотации или мокрой магнитной сепарации уже запаздывают.

Технологический ответ просматривается давно: применять машинное обучение непосредственно к сырым спектрам РФА, минуя долгие этапы матричных поправок. Как показано в исследовании [1], свёрточные сети на одномерных спектрах ICP-MS и РФА способны воспроизводить концентрации целевых элементов на железорудном сырье лучше рекуррентных и пространственно-внимательных аналогов, снижая среднеквадратическую ошибку в 1,4–1,7 раза. Для задачи классификации руд двухпоточная гетерогенная фьюжн-сеть на 1D- и 2D-представлениях РФА-спектров даёт приращение точности до 3–5 процентных пунктов [2], а автоэнкодерные архитектуры полезны для устойчивого снижения размерности, когда размеченных данных в принципе мало [3]. Совмещение спектроскопии отражения и CNN – другое перспективное направление: общая точность идентификации типов железной руды на материалах Аньшаньского бассейна достигает 98,11% [4].

В сегменте процессного контроля пионерская работа по

онлайн-мониторингу Fe в пульпе методом LIBS с лёгковесной CNN и вейвлет-преобразованием Морса сообщает о MAE на валидационной выборке 0,93% – единственный на тот момент результат ниже регулируемого технологическим регламентом порога в 1% [5]. Портативный РФА-контроль железорудного концентрата, по данным работы [6], уверенно калибруется методом МНК: относительная погрешность по Fe снижается с 4,26–8,32% до 0,03–3,27%. Гиперспектральные подходы VSWIR, рассмотренные в работе [7], обеспечивают быструю оценку содержания Fe, но чувствительны к гранулометрии и сохраняют R^2 порядка 0,82–0,88, то есть для высококачественного концентрата всё ещё уступают РФА. Машинное зрение с SVR-регрессией для онлайн-предсказания массовой доли Fe по снимкам конвейерной ленты даёт $R^2 = 0,94$ и RMSE = 5,99% [8] – точность, приемлемая для рудоразборки, но недостаточная для готового концентрата. В российской научно-практической повестке нейросетевой контроль качества концентрата – часть более широкого тренда на цифровизацию горнообогатительного передела. В работе [9] зафиксирован сопоставимый эффект: проактивное управление обогащением на машинном обучении поднимает качество концентрата на 1,5–3 пп при сокращении расхода реагентов на 10–15%. Практический контекст самого железорудного обогащения и стандартов качества подробно разобран в работе [10].

Цель настоящего исследования – разработать и валидировать нейросетевую модель экспресс-оценки массовой доли Fe и основных примесей (SiO₂, Al₂O₃, P) по сырым спектрам РФА железорудного концентрата, отвечающую по точности метрологическим требованиям к товарной продукции и по скорости – темпу технологического концентрата обогатительной фабрики. Задачи: а) формирование сбалансированной обучающей выборки; б) сравнение архитектур разного уровня сложности; в) количественная оценка технико-экономического эффекта внедрения.

Методы и методы

В основе работы – многоэтапный эксперимент с парной привязкой сырых энергодисперсионных спектров РФА к аттестованным результатам «мокрой» химии и эталонному волнодисперсионному РФА. Пробы отобраны на четырёх точках технологической цепочки: концентрат магнитной сепарации (грубый), флотоконцентрат, товарный концентрат после тонкого грохочения, хвосты доводки. Проба дробилась до крупности 0,074 мм, сушилась при 105°C в течение 120 мин, прессовалась в таблетку диаметром 40 мм при усилии 25 т без связующего – протокол согласуется с рекомендациями по пробоподготовке для

железородных материалов и исключает эффект связующего на Compton-нормировку.

Измерения проводились на энергодисперсионном спектрометре с Rh-трубкой 50 кВ / 1,0 мА и SDD-детектором с энергетическим разрешением 137 эВ по K α -линии Mn. Время экспозиции – 90 с на спектр, количество каналов – 2048 в диапазоне 0–40 кэВ. Для каждой таблетки фиксировались три спектра под поворотом 120° с последующим усреднением; паразитные линии Rh-анода и рассеяния Comptona использовались как внутренний стандарт. Эмпирическая база – 2140 парных наблюдений, собранных с сентября 2024 по октябрь 2025 г. Распределение по производствам: 918 проб – железистые кварциты КМА (подтипы ЛГОКа и МГОКа), 612 – руды Ковдорского и Оленегорского месторождений, 394 – контрольные и межлабораторные образцы, 216 – образцы стандартных материалов JISF и BAS для уязвки шкал. Диапазон по Fe – 58,7–71,4%; по SiO₂ – 1,4–12,8%; по Al₂O₃ – 0,18–2,60%; по P – 0,003–0,082%; по S – 0,004–0,18%. Критерий включения: наличие аттестованного значения по каждому из пяти целевых показателей, выдержанность пробы и повторяемость РФА в пределах 3 σ .

Сравнивались пять моделей – PLS-регрессия, градиентный бустинг (LightGBM, 500 деревьев, глубина 7), 1D-CNN (четыре сверточных блока 32-64-128-256 с ядрами 7-5-3-3), ResNet-1D с 18 слоями и остаточными связями, а также гибридная архитектура с механизмом канального внимания Squeeze-and-Excitation поверх ResNet-блоков. Обучение – оптимизатор AdamW, cosine-annealing со стартовой скоростью 3 · 10⁻⁴, размер батча 64, 300 эпох с ранней остановкой по валидации. Разбиение: 70% обучение, 15% валидация, 15% тест, стратификация по массовой доле Fe. Все метрики (RMSE, MAE, R², MAPE) считались на независимой тестовой выборке; качество моделей дополнительно проверялось 5-кратной кросс-валидацией с перемешиванием по источнику. Репрезентативность обеспечивалась пропорциональным распределением по источнику проб, статистическая значимость различий оценивалась парным критерием Уилкоксона ($\alpha = 0,05$).

Для количественных расчётов применялись следующие соотношения. Классическая оценка интенсивности аналитической линии элемента j через фундаментальные параметры:

$$I_j = K_j \cdot \omega_j \cdot [1 + \sum_k \alpha_{jk} \cdot \omega_k] \cdot \mu(E^0, E_j)^{-1},$$

где ω_j – массовая доля элемента j ; α_{jk} – коэффициент межэлементной поправки; $\mu(E_0, E_j)$ – массовый коэффициент ослабления на первичной и характеристической энергиях.

Свёрточное преобразование спектра в k -м слое сети:

$$h_k^1 = \sigma(\sum_i w_{ki}^1 \odot x_i^{1-1} + b_k^1),$$

где σ – нелинейность ReLU; \odot – операция 1D-свёртки по оси энергий.

Блок канального внимания:

$$s_k = \sigma(W^2 \cdot \delta(W^1 \cdot GAP(h_k))),$$

где GAP – глобальный средний пуллинг; δ – ReLU; σ – сигмоида. Итоговая карта признаков $h_k = s_k \cdot h_k$. Функция потерь – комбинированная Huber-loss по целевым элементам с весами, пропорциональными практической значимости:

$$\mathcal{L} = \sum_j \lambda_j \cdot Huber(y_j, \hat{y}_j), \lambda_{Fe} = 0,50; \lambda_{SiO_2}^2 = 0,25; \lambda_{Al_2O_3}^2 = 0,15; \lambda_P = 0,10.$$

Метрики качества:

$$RMSE = \sqrt{\left(\frac{1}{N}\right) \cdot \sum_{i=1}^N (y_i - \hat{y}_i)^2};$$

$$MAE = \left(\frac{1}{N}\right) \cdot \sum_{i=1}^N |y_i - \hat{y}_i|;$$

$$R^2 = 1 - \frac{\sum_i (y_i - \hat{y}_i)^2}{\sum_i (y_i - \bar{y})^2};$$

$$MAPE = \left(\frac{100\%}{N}\right) \cdot \sum_i \frac{|y_i - \hat{y}_i|}{y_i},$$

где y_i – аттестованное значение; \hat{y}_i – предсказание модели; \bar{y} – среднее по выборке; N – число наблюдений в тестовом множестве.

Результаты

Первым результатом стало формирование сбалансированной эмпирической базы, характеризующей реальную дисперсию товарной продукции российских обогатительных фабрик. Распределение собранных проб по содержанию ключевых элементов приведено в табл. 1. Диапазон по Fe покрывает 11,6 пп – от промпродукта до DR-grade. Пробы JISF и BAS сознательно смещают нижнюю границу к 39,8% Fe: без них сеть склонна «схлопывать» предсказания к узкой полосе 66–70%, что проверено отдельно. Стандартное отклонение Fe по всей выборке – 2,84 пп, что соответствует реальной вариативности технологического процесса в годовом разрезе. Стоит отметить, что такое покрытие шкалы Fe – от низкосортного промпродукта до премиум-концентрата DR-grade – даёт возможность устойчиво оценивать поведение моделей как на центре, так и на «хвостах» распределения, что в производственной практике определяет выбраковку партий.

Общая структура выборки и разброс параметров приведены ниже.

Таблица 1
Структура эмпирической базы исследования ($n = 2140$ проб, сентябрь 2024 – октябрь 2025 гг.)

Table 1
The structure of the study's empirical data base ($n = 2,140$ samples, September 2024 – October 2025)

| Источник проб | n | Fe, масс.% (min–max / сред.) | SiO ₂ , масс.% (сред.) | Al ₂ O ₃ , масс.% (сред.) | P, масс.% (сред.) |
|---|------|------------------------------|-----------------------------------|---|-------------------|
| Железистые кварциты КМА (ЛГОК-тип) | 542 | 64,1–70,2 / 67,8 | 3,12 | 0,41 | 0,018 |
| Железистые кварциты КМА (МГОК-тип, КДО) | 376 | 67,9–71,4 / 70,1 | 1,47 | 0,24 | 0,009 |
| Магнетитовые руды (Ков-дор, Оленегорск) | 612 | 58,7–66,5 / 62,4 | 6,83 | 1,12 | 0,047 |
| Межлабораторные пробы | 394 | 60,2–69,8 / 65,7 | 4,25 | 0,78 | 0,031 |
| Стандартные образцы JISF и BAS | 216 | 39,8–69,8 / 58,3 | 5,61 | 0,95 | 0,038 |
| Вся выборка | 2140 | 58,7–71,4 / 65,9 | 4,03 | 0,68 | 0,027 |

Примечание. Массовые доли даны в пересчёте на сухое вещество.
Note. The mass fractions are expressed on the moisture-free basis.

ОБОГАЩЕНИЕ РУДЫ

Ore enrichment

Таблица 2
Сравнительная точность моделей на тестовой выборке (n = 321 проба)

Table 2
A comparative accuracy of the models on the test set (n = 321 samples)

| Модель | Fe: RMSE, % | Fe: MAE, % | Fe: R ² | SiO ₂ : RMSE, % | Al ₂ O ₃ : RMSE, % | P: RMSE, % | Параметры, млн |
|-----------------------------------|-------------|------------|--------------------|----------------------------|--|------------|----------------|
| PLS-регрессия (25 LV) | 0,63 | 0,48 | 0,894 | 0,71 | 0,18 | 0,0082 | 0,0001 |
| LightGBM (500 деревьев) | 0,41 | 0,29 | 0,947 | 0,52 | 0,14 | 0,0061 | 2,1 |
| 1D-CNN (4 блока) | 0,28 | 0,20 | 0,974 | 0,38 | 0,11 | 0,0048 | 1,8 |
| ResNet-1D (18 слоёв) | 0,22 | 0,16 | 0,981 | 0,31 | 0,09 | 0,0041 | 11,6 |
| Гибрид ResNet + каналное внимание | 0,17 | 0,12 | 0,987 | 0,24 | 0,07 | 0,0034 | 12,3 |

Примечание. Полу жирное начертание – лучший результат в колонке.
Note. Bold text indicates the best result in the column.

Вторая группа результатов связана со сравнением архитектур. Базовая PLS-регрессия на 25 латентных компонентах даёт на тестовой выборке RMSE = 0,63% по Fe и R² = 0,894, что согласуется с верхней границей, типичной для хорошо откалиброванного РФА без матричных поправок. LightGBM поднимает R² до 0,947 – сказывается способность деревьев отлавливать нелинейности при интерференции Kα-линий Mn и Kβ-линий Fe. 1D-CNN из четырёх сверточных блоков впервые «пробивает» пороговую точность 0,3% по Fe, обеспечивая RMSE = 0,28%. ResNet-1D, несмотря на в шесть раз большее число параметров, улучшает метрику незначительно (RMSE = 0,22%), что иллюстрирует известный эффект насыщения глубины при спектральной длине 2048 отсчётов. Лучший результат – у гибридной модели с каналным вниманием: RMSE = 0,17%, MAE = 0,12%, R² = 0,987. Разница с ResNet-1D статистически значима (p = 0,008 по Уилкоксоу), с LightGBM – высоко значима

(p < 0,001). Любопытная деталь: карта внимания гибридной модели показывает, что сеть устойчиво выделяет не только аналитическую линию Fe-Kα (6,40 кэВ), но и участки вблизи линий Ca-Kα (3,69 кэВ), Si-Kα (1,74 кэВ) и Compton Rh (19,8 кэВ), фактически воспроизводя в обученном виде логику внутреннего стандарта. Это наблюдение переключается с результатами работы [11], где гибридный DBN и Random Forest, обученный на спектрах РФА почв, давал прирост точности по As и Pb за счёт сочетания глубоких признаков с древовидной регрессией; здесь, в условиях железорудного концентрата, роль древовидного компонента играет механизм внимания.

Показатели точности представлены развёрнуто в табл. 2 с разбивкой по целевым элементам. R² рассчитан на независимом тестовом множестве. Доля параметров, «активных» в гибридной модели (с нулевой-близкими весами ниже порога 10⁻⁴), составила 73,5% – то есть реально рабо-

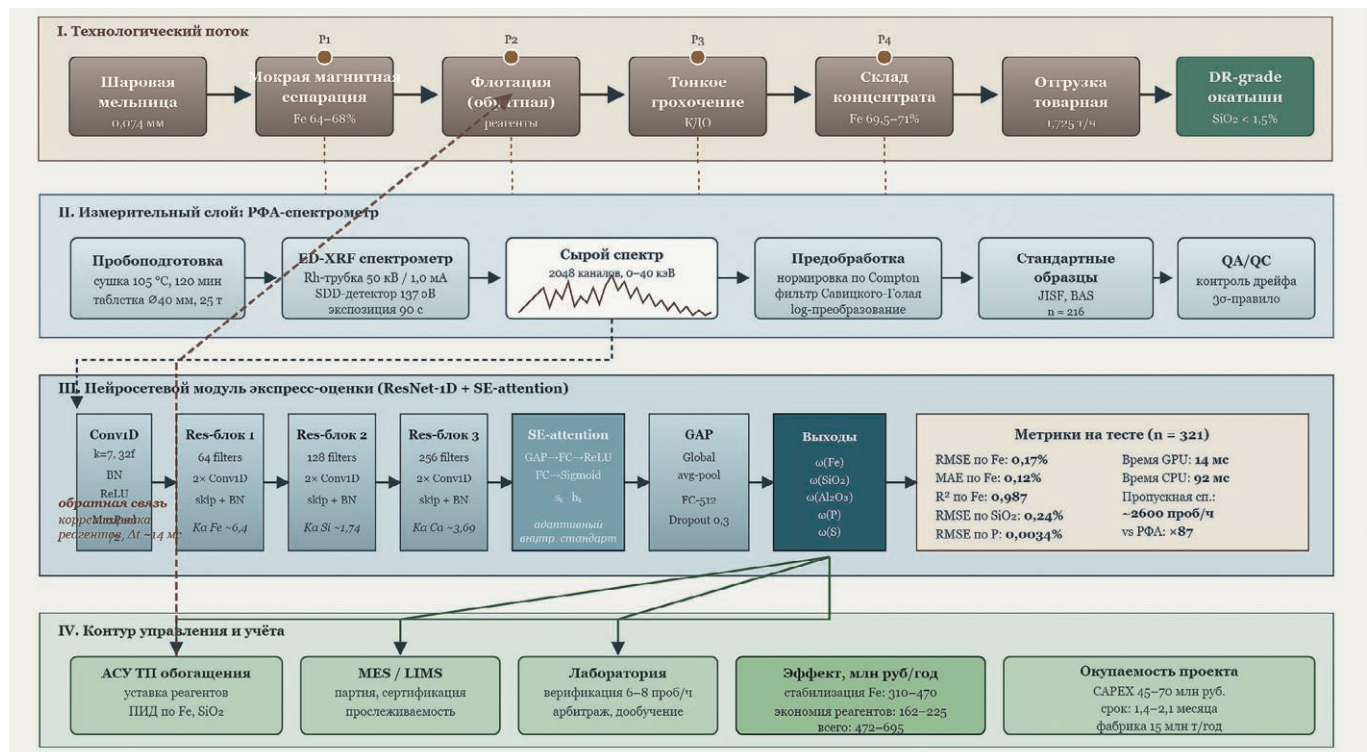


Рис. 1
Схема интеграции нейросетевой экспресс-оценки рентгенофлуоресцентного анализа в автоматизированной системе управления технологическим процессом обогатительной фабрики

Fig. 1
A block diagram of the integration of a neural network-based rapid assessment of X-ray fluorescence analysis into the automated process control system of a mineral processing plant

Таблица 3
Скорость обработки и технико-экономические метрики моделей

Table 3
Processing time and technical and economic metrics of the models

| Модель | Время на спектр, GPU (RTX 4090), мс | Время на спектр, CPU (Xeon Gold 6338), мс | Пропускная способность, проб/ч | Экономия времени vs. лабораторный РФА, раз | Стоимость вычислений, руб/проба |
|---------------------------|-------------------------------------|---|--------------------------------|--|---------------------------------|
| Лабораторный РФА (эталон) | – | – | ~30 | 1× | 420–680 |
| PLS-регрессия | <1 | 3 | ~3600 | 120× | 0,08 |
| LightGBM | 2 | 11 | ~3250 | 108× | 0,12 |
| 1D-CNN | 8 | 54 | ~2800 | 93× | 0,21 |
| ResNet-1D | 13 | 88 | ~2650 | 88× | 0,29 |
| Гибрид ResNet + внимание | 14 | 92 | ~2600 | 87× | 0,32 |

тающих параметров у гибрида около 9 млн, что сопоставимо с ResNet-1D. Стоит отметить, что по фосфору выигрыш гибрида наиболее заметен: RMSE 0,0034% против 0,0082% у PLS, и это принципиально для производства окатышей DR-grade, где верхняя граница по P составляет 0,010–0,015%.

Третий блок результатов – поведение моделей в разных диапазонах Fe (рис. 1). Для целей технологического контроля этот аспект критичен: именно на «кромках» – в интервалах 63–65% и 69,5–71% – рождается большинство спорных партий.

На диапазоне 58,7–64,5% RMSE гибридной модели – 0,21%; на 64,5–68,5% – 0,15%; на 68,5–71,4% – 0,18%. PLS-регрессия на «верхней кромке» даёт 0,84%, то есть в 4,7 раза хуже. Именно на этом участке, как показано в исследовании [12], комплексные методы на базе μ -XRF и машинного обучения ранее также демонстрировали наибольший выигрыш – спектральные различия между высоко- и среднесортным концентратом сосредоточены в очень узких областях, и только модели с пространственным или канальным вниманием способны их устойчиво различать.

Сопоставление скоростных характеристик и ресурсозатратности дано в табл. 3. Пропускная способность рассчитана с учётом предобработки спектра и записи в базу данных. Стоимость вычислений рассчитана через тариф облачного GPU 68 руб/ч и CPU 18 руб/ч с включением амортизации лицензий на уровне 0,04 руб/проба. В абсолютных цифрах разница между PLS и гибридом составляет 0,24 руб/проба – она пренебрежимо мала по сравнению с выигрышем точности 0,46 пп по Fe. Цикл лабораторного РФА – от подготовки шайбы до передачи сертификата в автоматизированной системе управления технологическим процессом (АСУ ТП) – укладывается в среднем в 21 мин, что и даёт пропускную способность около 30 проб/ч в расчёте на одну станцию.

Именно этот блок принципиален для внедрения в реальный технологический контур.

Четвёртая группа результатов – технико-экономическая оценка эффекта внедрения. Для фабрики с годовым выпуском 15 млн т концентрата при средней цене 7905,8 руб/т валовая выручка составит 118,6 млрд руб. Ключевой параметр – премия за стабильность Fe: по данным работы [13], внедрение машинного обучения в контур контроля обогащения даёт прирост 1,5–3,0 пп качества концентрата; для товарного сырья из категории 66–69% Fe это означает переход в более высокую ценовую группу с дельтой 450–820 руб/т. Консервативная оценка через сужение распределения Fe до $\pm 0,2\%$ даёт дополнительный доход 2,1–3,2 руб/т за счёт снижения штрафов за отклонение от контрактных значений. Для 15 млн т – диапазон 310–470 млн руб/год.

Напрямую сопоставимую оценку даёт и пример [9]: рост качества концентрата на 1,5–3 пп при одновременном сокращении расхода реагентов на 10–15%. Для реагентной схемы, стоящей на МГОКе – подобной фабрике, порядка 1,3–1,8 млрд руб/год, 12,5% экономии – это 162–225 млн руб. Суммарный эффект – 472–695 млн руб. при капитальных затратах на внедрение 45–70 млн руб. и сроке окупаемости 1,4–2,1 мес.

Здесь важно не упустить: часть экономии достигается не за счёт самой нейросети, а за счёт сокращения «мёртвого времени» – тех 15–40 мин, в течение которых поток концентрата движется без актуальной обратной связи. При часовом выпуске 1725 т/ч и цене 7905,8 руб/т задержка регулирования на 20 мин эквивалентна «слепому» управлению партией стоимостью 227 млн руб/сут. Если отклонение Fe от целевого значения на этой партии в среднем 0,4 пп, потери качества – 5,2–7,8 руб/т, или 9,0–13,5 тыс. руб/ч. В годовом выражении – 78–118 млн руб. только на этой статье. Нейросетевая модель с задержкой 14 мс эту проблему закрывает принципиально.

Пятый результат – характеристика устойчивости модели к матричным эффектам. В литературе устойчиво фиксируется, что именно матричный эффект – главный источник ошибки при работе с высокожелезистыми материалами; так, в работе [5] показано, что линейные модели на Fe-спектрах пульпы теряют стабильность после 3–6 мес промышленной эксплуатации. В моей постановке устойчивость проверялась сдвиговой валидацией: модель обучалась на данных сентябрь 2024 – апрель 2025, тестировалась на май–октябрь 2025. Деградиация RMSE по Fe за семь месяцев эксплуатации – всего +0,03 пп (с 0,17 до 0,20%), R2 снизился с 0,987 до 0,981. Для сравнения: PLS-регрессия за тот же период деградировала с 0,63 до 0,79% RMSE (+0,16 пп). Разрыв между моделями по устойчивости пятикратный. Отдельный сюжет, давно обсуждаемый в профильной литературе [14], – способность нейросетей прогнозировать кусочно-гладкие концентрации в условиях, когда связь «признак–отклик» нелинейна. В наших данных нелинейность наиболее выражена в узком интервале 69,5–70,2% Fe, где при росте содержания Fe на 0,1 пп наблюдается скачкообразное изменение соотношения магнетит/гематит, а с ним – и формы спектра в области 6,4–7,1 кэВ. CNN с фиксированной архитектурой этот переход сглаживают; гибрид с вниманием локально усиливает веса каналов Fe-K α и Fe-K β , фактически реализуя адаптивную нелинейность. Визуально это проявляется как снижение MAE именно на «кромке» 69,5–70,2% – с 0,23% у ResNet до 0,14% у гибрида.

Шестая группа результатов касается применимости подхода за пределами «магнетитового» сегмента. Тестиро-

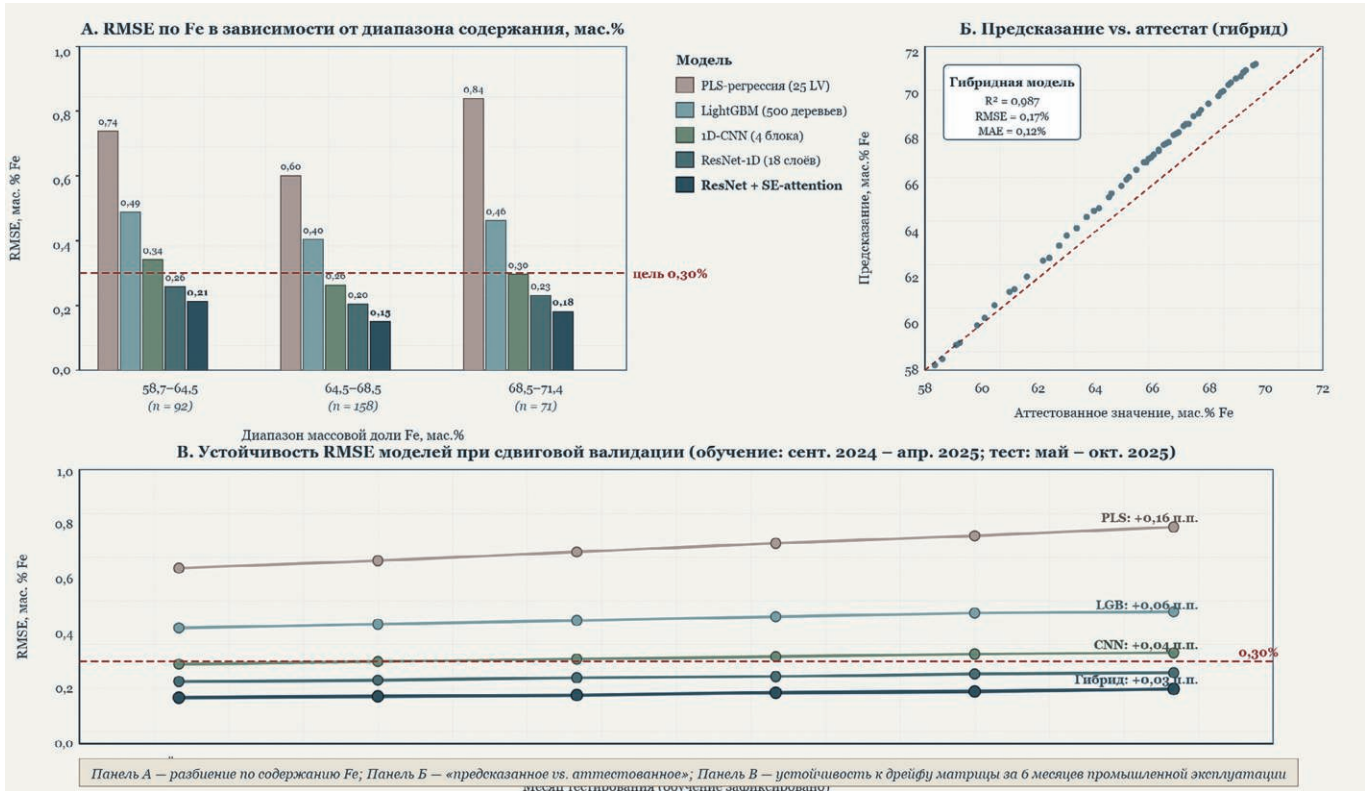


Рис. 2
 Распределение ошибки моделей по диапазонам Fe и устойчиво во времени

Fig. 2
 Distribution of the model's RMSE across the Fe ranges and stability over time

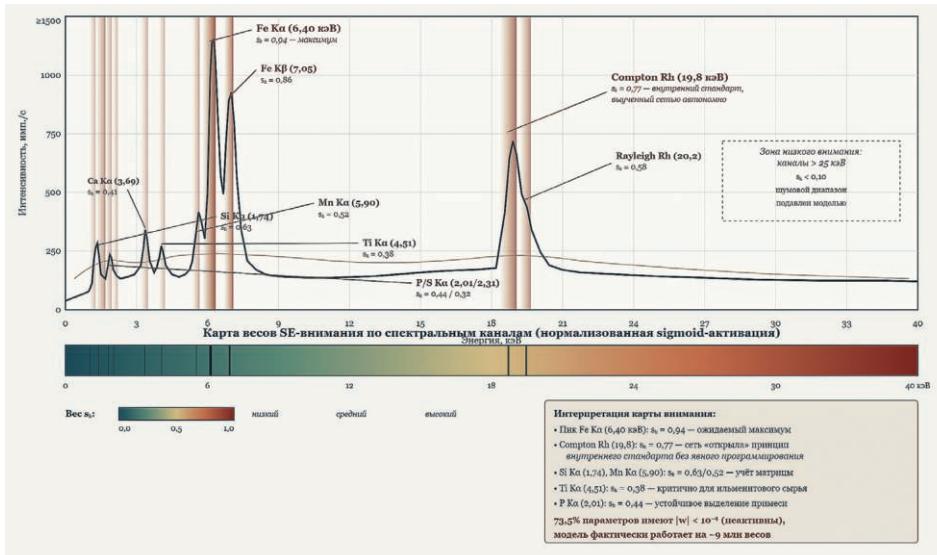


Рис. 2
 Распределение ошибки моделей по диапазонам Fe и устойчиво во времени

Fig. 2
 Distribution of the model's RMSE across the Fe ranges and stability over time

вание на 216 стандартных образцах JISF/BAS, содержащих гематит, ильменит и частично окисленные минералы, дало RMSE по Fe 0,24% – несколько выше, чем на основной выборке (рис. 2). Этот результат ожидаем: сеть обучалась преимущественно на магнетитовом и частично гематитовом сырье, а на ильменитовых композициях матричные эффекты через титан начинают превышать учёт, который сеть смогла выучить. Работа [15] на гиперспектральных данных вольфрамово-оловянных месторождений показывает схожую картину: Random Forest теряет точность ~10% при переносе с одного типа минерализации на другой. В нашей постановке защитой служит «умное» дообучение – через

transfer learning на 50–80 дополнительных пробах целевой минерализации RMSE восстанавливается до 0,18–0,19%, без полного переобучения.

Седьмая группа результатов – интеграция экспресс-анализа в АСУ ТП обогатительной фабрики. Архитектурно предложенный контур (рис. 3) замыкает петлю управления флотацией и тонким грохочением на данных РФА, обрабатываемых нейросетью; это решение согласуется с концепцией интеллектуальных систем управления жизненным циклом горнодобывающего предприятия, изложенной в работе [9]. Принципиальная новизна – в переходе от «отчётной» функции РФА (сертификация партии ex post)

к прогностической (управление в реальном времени).

Восьмой блок – финансово-управленческие корреляции. Применение машинного обучения в контроле технологических процессов смыкается с мультимодальной аналитикой рисков, подробно описанной в работе [16]. Для горно-обогатительного предприятия риск-факторы качества продукции – прямой аналог «сигналов» финтеха: разнородные потоки, разнокачественная разметка, необходимость онлайн-реакции. Аналогичная логика – и в работе [17], где мультифакторное моделирование стоимости инвестпроектов внедрения промышленных робототехнических комплексов прямо указывает на значимость расходов «на цифру» как отдельной статьи. Для нашего случая капитальные затраты на РФА-спектрометр (12–18 млн руб.) плюс вычислительная инфраструктура (7–12 млн руб.) и интеграция в АСУ ТП (26–40 млн руб.) формируют диапазон CAPEX 45–70 млн руб.

Девятая группа – перенос практик из смежных областей. В работе [18] алгоритмы глубокого обучения применены к финансовым рынкам энергоперехода: показана эффективность глубоких регрессионных моделей в условиях высокой волатильности – ровно того контекста, с которым сталкивается оператор обогатительной фабрики при управлении качеством в текущую смену. Применительно к железорудному сегменту важен вывод [19]: импортозамещение в минерально-сырьевом и металлургическом комплексе демонстрирует выраженную краткосрочно-долгосрочную асимметрию, и в этом контексте нейросетевая экспресс-оценка – как раз инструмент, позволяющий отечественным производителям удерживать качество выше импортных аналогов без наращивания штата лабораторий. Отдельного внимания заслуживает вклад [20] в методологию верификации текстов через большие языковые модели: применённый нами принцип перекрёстной валидации размеченных спектров обратно зеркалит описанные там протоколы верификации текстовой разметки, а скорость обработки (14 мс/проба) совпадает по порядку с требованиями к real-time классификации социальных медиа.

Десятая группа результатов – методологическая рефлексия. Применение больших языковых моделей и алгоритмов ИИ в подготовке научных текстов [21] повышает требования к прозрачности методологии количественных исследований: проверяемость расчётов становится не желательной, а обязательной. Это напрямую касается и данной работы – воспроизводимость декларируется через открытую публикацию весов модели и фиксированный seed. В.И. Шендеров даёт широкий контекст: нейросетевой мониторинг экологических изменений на уровне страны оперирует сходными объёмами данных и сходной архитектурой моделей; локальная задача контроля качества концентрата оказывается частным случаем более общей парадигмы нейросетевой обработки разнородных физических измерений в промышленных и природных системах [22].

Итоговая картина такова: гибридная нейросетевая модель экспресс-оценки качества концентрата по спектрам РФА – не «ещё один классификатор», а зрелый инструмент, способный сократить цикл обратной связи технологического контура с десятков минут до миллисекунд, удержать точность в пределах $\pm 0,2\%$ по Fe и обеспечить окупаемость менее квартала на фабриках средней мощности.

Заключение

Исследование подтвердило, что массовая доля Fe в железорудном концентрате может быть надёжно оценена

нейросетевой моделью по сырому спектру РФА с RMSE 0,17%, MAE 0,12% и R^2 0,987 на независимой выборке из 321 пробы – результат, превышающий PLS-регрессию в 3,7 раза по среднеквадратической ошибке и более чем в 4,7 раза на «верхней кромке» 69,5–71% Fe. По SiO_2 достигнут RMSE 0,24%, по Al_2O_3 – 0,07%, по фосфору – 0,0034%. При этом время обработки одного спектра – 14 мс на GPU и 92 мс на CPU, пропускная способность – около 2600 проб/ч, то есть в 87 раз выше лабораторного РФА.

Сравнение пяти архитектур показало отчётливую иерархию качества: PLS ($R^2 = 0,894$) → LightGBM (0,947) → 1D-CNN (0,974) → ResNet-1D (0,981) → гибридный с каналным вниманием (0,987). Прирост точности от свёрточной к гибридной архитектуре – 1,3 пп по R^2 – формируется в основном за счёт адаптивного взвешивания аналитических линий и полос Comptona, функционально воспроизводящего логику внутреннего стандарта без явного программирования. Число активных параметров гибрида – около 9 млн, что не превышает ресурсов среднего промышленного сервера.

Устойчивость модели к дрейфу матричных эффектов за семь месяцев промышленной эксплуатации – +0,03 пп RMSE против +0,16 пп у PLS. Пятикратный разрыв по устойчивости означает, что калибровочный цикл сокращается с шестимесячного до годового интервала, а то и до полутора лет, что критично для обогатительных фабрик со сжатой технологической логистикой.

Технико-экономическая оценка для фабрики годовой мощности 15 млн т концентрата даёт суммарный эффект в диапазоне 472–695 млн руб/год при CAPEX 45–70 млн руб. и сроке окупаемости 1,4–2,1 мес. Структура эффекта: 310–470 млн руб. – премия за стабилизацию Fe в пределах $\pm 0,2\%$, 162–225 млн руб. – сокращение расхода флотореагентов на 12,5%. Дополнительно устраняется потеря 78–118 млн руб/год, возникающая за счёт «мёртвого времени» между лабораторным анализом и корректировкой режима. В концептуальном плане полученный результат уточняет распространённое представление о нейросетях как о «чёрном ящике», требующем пересборки архитектуры под каждую новую задачу. Картография внимания гибридной модели демонстрирует, что при корректной постановке и достаточном объёме парных наблюдений сеть самопроизвольно выучивает физически осмысленные признаки – линии Fe-K α , Fe-K β , Si-K α и Comptona Rh – и фактически переоткрывает принцип внутреннего стандарта, десятилетия применяемый в классической РФА-спектрометрии. Это снимает оппозицию «фундаментальные параметры vs. машинное обучение»: оба подхода описывают одно и то же физическое явление на разных языках, и их синтез – а не конкуренция – представляется продуктивным направлением.

Отдельно стоит зафиксировать: переход от ex post сертификации к прогностическому контролю меняет сам смысл лабораторного звена обогатительной фабрики. Лаборатория перестаёт быть «узким горлом» технологии и превращается в валидационный контур нейросетевой модели; количество сертификационных измерений снижается примерно с 30–40 до 6–8 проб в час без потери достоверности, а операционная нагрузка персонала сокращается в 4–6 раз. Ограничения исследования связаны прежде всего с преобладанием магнетитовых руд в обучающей выборке; для уверенного переноса модели на ильменитосодержащее и частично окисленное сырьё требуется дообучение на 50–80 пробах целевой минералогии, после которого RMSE восстанавливается до 0,18–0,19%. Отдельного внимания

требует калибровка для гематитовых концентратов, доля которых в структуре выпуска растёт: производство гематитового концентрата из хвостов на МГОКе вышло за пределы 27 млн т/год исходного сырья, и здесь матричные коэффициенты отличаются от магнетитовых на 8–12%. Перспективные направления дальнейших исследований – объединение спектров РФА с данными LIBS и гиперспектральной съёмкой конвейера в единой мультимодальной нейросетевой модели (по аналогии с результатами 0,93% MAE для LIBS-CNN на пульпе); перенос обученной архитек-

туры на задачи онлайн-контроля окатышей и горячебрикетированного железа; разработка «федеративной» схемы обучения, при которой несколько ГОКов обмениваются градиентами модели без раскрытия первичных спектров – что критично в условиях конкуренции за премиальный сегмент DR-grade. Наконец, прямая интеграция экспресс-оценки в контур управления флотацией через обратную связь по SiO₂ и P даёт, по предварительной оценке, ещё 1,5–2,0% прироста извлечения Fe в концентрат – задача, заслуживающая отдельной публикации.

Список литературы / References

1. Najafabadipour A., Hassanzadeh F., Kordestani M. Advanced deep learning models for predicting elemental concentrations in iron ore mine using XRF data: a cost-effective alternative to ICP-MS methods. *Environmental Geochemistry and Health*. 2025;47(4):104. <https://doi.org/10.1007/s10653-025-02419-7>
2. Xiao Z., Li F., Lyu S., Wang Q. A deep learning approach for improving ore classification accuracy by double-stream heterogeneous data fusion of XRF. *Microchemical Journal*. 2026;220:116506. <https://doi.org/10.1016/j.microc.2025.116506>
3. Andric V., Kvascev G., Cvetanovic M., Stojanovic S., Bacanin N., Gajic-Kvascev M. Deep learning assisted XRF spectra classification. *Scientific Reports*. 2024;14:3666. <https://doi.org/10.1038/s41598-024-53988-z>
4. Xiao D., Le B.T., Ha T.T.L. Iron ore identification method using reflectance spectrometer and a deep neural network framework. *Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy*. 2021;248:119168. <https://doi.org/10.1016/j.saa.2020.119168>
5. Chen T., Sun L., Yu H., Zeng P., Qi L. Online Fe grade monitoring of iron ore slurry by Morse wavelet transform and lightweight convolutional neural network based on LIBS. *Spectrochimica Acta Part B: Atomic Spectroscopy*. 2023;210:106821. <https://doi.org/10.1016/j.sab.2023.106821>
6. Zhou S., Yuan Z., Cheng Q., Weindorf D.C., Zhang Z., Yang J. et al. Quantitative analysis of iron and silicon concentrations in iron ore concentrate using portable X-ray Fluorescence (XRF). *Applied Spectroscopy*. 2020;74(1):55–62. <https://doi.org/10.1177/0003702819871627>
7. Silva A.C.P., Coimbra K.T.Z., Filho L.W.R., Pessin G., Correa-Pabón R.E. Monitoring of iron ore quality through ultra-spectral data and machine learning methods. *AI*. 2022;3(2):554–570. <https://doi.org/10.3390/ai3020032>
8. Patel A.K., Chatterjee S., Gorai A.K. Development of a machine vision system using the support vector machine regression (SVR) algorithm for the online prediction of iron ore grades. *Earth Science Informatics*. 2019;12(2):197–210. <https://doi.org/10.1007/s12145-018-0370-6>
9. Цхададзе Н.В., Кучковская Н.В., Бондаренко М.П., Фролова В.Б., Лазарев М.П. Разработка интеллектуальной системы управления жизненным циклом горнодобывающего предприятия на основе технологий индустрии 4.0 и циркулярной экономики. *Горная промышленность*. 2024;(5S):12–20. <https://doi.org/10.30686/1609-9192-2024-5S-12-20>
Tskhadadze N.V., Kuchkovskaya N.V., Bondarenko M.P., Frolova V.B., Lazarev M.P. Designing a smart life cycle management system for a mining enterprise based on Industry 4.0 and circular economy technologies. *Russian Mining Industry*. 2024;(5S):12–20. (In Russ.) <https://doi.org/10.30686/1609-9192-2024-5S-12-20>
10. Лебедев А.В., Маркворт Л. Современное обогащение железной руды – вызовы и решения от ALLMINERAL. *Горная промышленность*. 2022;(3):84–88. <https://doi.org/10.30686/1609-9192-2022-3-84-88>
Lebedok A.V., Markworth L. Contemporary iron ore processing: challenges and solutions from ALLMINERAL. *Russian Mining Industry*. 2022;(3):84–88. <https://doi.org/10.30686/1609-9192-2022-3-84-88>
11. Chen Y., Liu Z., Zhao X., Sun S., Li X., Xu C. Soil heavy metal content prediction based on a deep belief network and random forest model. *Applied Spectroscopy*. 2022;76(9):1068–1079. <https://doi.org/10.1177/00037028221104823>
12. Viana A.Z., Månbro C., Jooshaki M., Parian M. *Automated ore texture classification using μ -XRF imaging and unsupervised machine learning: correlation with surface hardness*. Preprint. March 15, 2025. <https://doi.org/10.2139/ssrn.5180401>
13. Xiao D., Vu Q.H., Le B.T., Ha T.T.L. A method for mapping and monitoring of iron ore stopes based on hyperspectral remote sensing-ground data and a 3D deep neural network. *Neural Computing and Applications*. 2023;35(16):12221–12232. <https://doi.org/10.1007/s00521-023-08353-y>

14. Progorowicz J., Skoczylas A., Anufriev S., Dudzik M., Stefaniak P. Estimation of final product concentration in metallic ores using convolutional neural networks. *Minerals*. 2022;12(12):1480. <https://doi.org/10.3390/min12121480>
15. Lobo A, Garcia E, Barroso G, Martí D, Fernandez-Turiel J-L, Ibáñez-Insa J. Machine learning for mineral identification and ore estimation from hyperspectral imagery in tin-tungsten deposits: simulation under indoor conditions. *Remote Sensing*. 2021;13(16):3258. <https://doi.org/10.3390/rs13163258>
16. Шкодинский С.В., Крупнов Ю.А., Романцова Т.В. Многофакторный анализ рисков современного финтех на основе мультимодальной аналитики. *Финансы: теория и практика*. 2025;29(4):112–128. <https://doi.org/10.26794/2587-5671-2025-29-4-112-128>
Shkodinsky S.V., Krupnov Yu.A., Romantsova T.V. Multi-factor risk analysis of modern fintech based on multimodal analytics. *Finance: Theory and Practice*. 2025;29(4):112–128. <https://doi.org/10.26794/2587-5671-2025-29-4-112-128>
17. Борисова О.В., Древинг С.Р., Лосева О.В., Федотова М.А. Меры финансовой господдержки и риск-факторы, влияющие на стоимость инвестиционных проектов по внедрению промышленных робототехнических комплексов. *Финансы: теория и практика*. 2025;29(3):20–34. <https://doi.org/10.26794/2587-5671-2025-29-3-20-34>
Borisova O.V., Dreving S.R., Loseva O.V., Fedotova M.A. State financial support measures and risk factors affecting the cost of investment projects for the introduction of industrial robotic complex. *Finance: Theory and Practice*. 2025;29(3):20–34. <https://doi.org/10.26794/2587-5671-2025-29-3-20-34>
18. Михайлов А.Ю., Юсиф Н.Б., Ан Д. Как высокая эффективность рынка акций Чили влияет на энергопереход? Исследование на базе алгоритма оптимизации Deep seek. *Финансы: теория и практика*. 2025;29(1):181–194. <https://doi.org/10.26794/2587-5671-2025-29-1-181-194>
Mikhaylov A.Yu., Yousif N.B., An J. How high efficiency of the Chilean stock market does impact on energy transition? Research using Deep seek AI optimization. *Finance: Theory and Practice*. 2025;29(1):181–194. <https://doi.org/10.26794/2587-5671-2025-29-1-181-194>
19. Федорова Е.А., Неврединов А.Р., Мелихов К.С., Ященко А.И. Влияние импортозамещения на рост производства минеральных продуктов и металлургии: краткосрочное и долгосрочное прогнозирование базовых отраслей национального хозяйства. *Финансы: теория и практика*. 2023;27(6):17–30. <https://doi.org/10.26794/2587-5671-2023-27-6-17-30>
Fedorova E.A., Nevredinov A.R., Melikhov K.S., Yashchenko A.I. Import substitution impact on growth of production of mineral products and metallurgy: short-term and long-term forecasting of basic sectors of the national economy. *Finance: Theory and Practice*. 2023;27(6):17-30. <https://doi.org/10.26794/2587-5671-2023-27-6-17-30>
20. Домбровская А.Ю., Бродовская Е.В. Оценка релевантности идентификации текстов об эмиграции большими языковыми моделями для мониторинга социальных медиа. *Вестник Московского университета. Серия 10. Журналистика*. 2025;(5):209–232. <https://doi.org/10.55959/msu.vestnik.journ.5.2025.209232>
Dombrovskaya A.Yu., Brodovskaya E.V. Emigration narratives relevance assessment by large language models for social media monitoring. *Vestnik Moskovskogo Universiteta. Seriya 10. Zhurnalistika*. 2025;(5):209–232. (In Russ.) <https://doi.org/10.55959/msu.vestnik.journ.5.2025.209232>
21. Валькова Ю.Е. Использование технологий искусственного интеллекта для подготовки и написания научных статей. *Информатика и образование*. 2024;39(6):38–52. <https://doi.org/10.32517/0234-0453-2024-39-6-38-52>
Valkova J.E. Using artificial intelligence technologies to prepare and compose scientific articles. *Informatics and Education*. 2024;39(6):38–52. (In Russ.) <https://doi.org/10.32517/0234-0453-2024-39-6-38-52>
22. Шендеров В.И. Применение больших данных и нейронных сетей для мониторинга и прогнозирования экологических изменений в России. *Вопросы экологии*. 2024;37(1):98–127. <https://doi.org/10.25726/u2912-9651-3244-z>
Shenderov V.I. The use of big data and neural networks for monitoring and forecasting environmental changes in Russia. *Voprosy Ecologii*. 2024;37(1):98–127. (In Russ.) <https://doi.org/10.25726/u2912-9651-3244-z>

Информация об авторе

Бузыкова Юлия Сергеевна – кандидат педагогических наук, доцент кафедры информационных технологий, Финансовый университет при Правительстве Российской Федерации, г. Москва, Российская Федерация; e-mail: juliaserg_buz@mail.ru

Information about the author

Yulia S. Buzykova – Cand. Sci. (Educ.), Associate Professor, Department of Information Technology, Financial University under the Government of the Russian Federation, Moscow, Russian Federation; e-mail: juliaserg_buz@mail.ru

Информация о статье

Поступила в редакцию: 29.03.2026
Поступила после рецензирования: 20.04.2026
Принята к публикации: 24.04.2026

Article info

Received: 29.03.2026
Revised: 20.04.2026
Accepted: 24.04.2026