

АТТ-CNN картирование порфировых Cu-Mo месторождений Удоканского типа

А.О. Кузьмина ✉, М.Ю. Ильина, К.Е. Лукичев, Н.Г. Преснякова, А.А. Татарников
Финансовый университет при Правительстве Российской Федерации, г. Москва, Российская Федерация
✉ aokuzmina@fa.ru

Резюме: Разведка медно-порфировых месторождений требует интеграции разнородных геопространственных данных для выявления слепого оруденения на глубинах до 2000 м. Сверточные нейронные сети с механизмом внимания (АТТ-CNN) демонстрируют точность классификации 95–98% в задачах минерального прогнозирования. Удоканское медное месторождение с запасами 26,7 млн т Cu при содержании 1,05% представляет эталонный объект стратиформной Cu-Ag минерализации в протерозойских метаосадочных комплексах Забайкалья. Исследование базируется на интеграции геохимических данных по 20 элементам, гравиметрических и магнитометрических съемок, мультиспектральных снимков для участка 12 000 км². Архитектура АТТ-CNN включает четыре сверточных блока с каналным механизмом внимания после второго и четвертого блоков. Обучение проведено на выборке 473 рудопроявлений медно-порфирового типа Северо-Американских Кордильер с последующим трансферным обучением для Удоканского района. Модель достигла точности 94,87% при AUC = 0,987 против базовой CNN с AUC = 0,970. Анализ весов внимания выявил доминирующую роль геохимических аномалий Cu, Mo, Co и структурных параметров. Выделено шесть пермиссивных трактов площадью 100–800 км² с вероятностью обнаружения промышленных концентраций 78–92%. Верификация показала, что 83% документированных рудопроявлений попадают в прогнозные контуры при охвате 9,7% территории.

Ключевые слова: глубокое машинное обучение, механизм внимания, геохимическое картирование, медные месторождения, Удоканское месторождение, прогнозное моделирование, трансферное обучение

Для цитирования: 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):135–142. <https://doi.org/10.30686/1609-9192-2026-1-135-142>

АТТ-CNN mapping of the Udokan-type Cu-Mo porphyry deposits

A.O. Kuzmina ✉, M.Yu. Ilyina, K.E. Lukichev, N.G. Presnyakova, A.A. Tatarnikov
Financial University under the Government of the Russian Federation, Moscow, Russian Federation
✉ aokuzmina@fa.ru

Abstract: Exploration of copper porphyry deposits requires integration of heterogeneous geospatial data to identify blind ore bodies at depths of up to 2000 m. Convolutional neural networks with attention-based mechanisms (ATT-CNN) demonstrate 95–98% classification accuracy in mineral prediction tasks. The Udokan copper deposit, with the reserves of 26.7 million tons of Cu at the grade of 1.05%, is a benchmark for stratiform Cu-Ag mineralization in Proterozoic metasedimentary complexes of Transbaikalia. The study is based on the integration of geochemical data for 20 elements, gravimetric and magnetic mapping, as well as multispectral images for a plot of 12,000 km² in area. The ATT-CNN architecture includes four convolutional blocks with a channel attention-based mechanism after the second and the fourth blocks. Training was performed on a dataset of 473 copper porphyry-type ore occurrences in the North American Cordillera, followed by transfer learning for the Udokan region. The model achieved an accuracy of 94.87% with AUC = 0.987 compared to the baseline CNN with AUC = 0.970. Analysis of the attention weights revealed the dominant role of the Cu, Mo, Co geochemical anomalies and structural parameters. Six permissive tracts with an area of 100–800 km² were identified with the probability of detecting commercial concentrations of 78–92%. Verification showed that 83% of the documented ore occurrences fall within the forecast contours, covering 9.7% of the territory.

Keywords: deep machine learning, attention-based mechanism, geochemical mapping, copper deposits, Udokan deposit, predictive modeling, transfer learning

For citation: 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. *Russian Mining Industry*. 2026;(1):135–142. (In Russ.) <https://doi.org/10.30686/1609-9192-2026-1-135-142>

Введение

Применение методов глубокого машинного обучения для структурного анализа рудных тел демонстрирует высокую эффективность в прогнозировании оптимальных зон добычи [1]. Оценка неоткрытых песчанниковых медных месторождений Кодаро-Удоканской области USGS выявила значительный потенциал региона с применением методологии пермиссивных трактов [2]. Устойчивое минеральное обеспечение требует совершенствования методов управления ресурсами и учета экологических ограничений [3]. Развитие топливно-энергетического сектора и минерально-сырьевой базы требует внедрения зеленых технологий для снижения углеродного следа [4].

Удоканское месторождение характеризуется конкордантным возрастом титанита $1896,2 \pm 6,2$ млн лет, подтверждающим синорогенное формирование Cu-Ag минерализации при сборке суперконтинента Колумбия [5]. Методы картирования минеральной перспективности через big data analytics и алгоритмы глубокого обучения трансформируют подходы к прогнозированию месторождений [6]. Геология и руды Удоканского медного месторождения представляют эталонный объект стратиформной минерализации в протерозойских метасадочных комплексах Забайкалья с запасами 26,7 млн т Cu при содержании 1,05% [7]. Картирование минеральной перспективности с использованием attention-based convolutional neural networks повышает точность прогнозирования на 2–4% относительно базовых CNN архитектур [8]. Эффективное управление минерально-сырьевыми проектами требует интеграции современных подходов к организации научно-исследовательских работ и кадрового обеспечения геологоразведочной отрасли [9]. Синергетический подход к управлению карьерами с применением больших данных и интеллектуальных систем предиктивной аналитики обеспечивает оптимизацию производственных процессов [10]. Использование зеленых технологий российскими нефтегазовыми компаниями при добыче углеводородов демонстрирует эффективность снижения углеродного следа [11]. Deep Forest modeling как интерпретируемый метод глубокого обучения достигает точности 90,4% при картировании порфирировых Cu месторождений Северной Америки [12]. Совершенствование кластерного ландшафта минерально-сырьевых регионов выступает фактором обеспечения экономической безопасности при разработке месторождений [13]. Оптимизация процессов стратегического планирования геологоразведочных работ требует учета экономических и технологических факторов [14]. Интерпретируемые архитектуры attention branch convolutional neural networks позволяют идентифицировать геохимические аномалии, связанные с минерализацией [15]. Геохимические методы опробования донных отложений и индикаторных минералов широко применяются для минерального прогнозирования в условиях ледниковых территорий [16]. Обзор методов mineral prospectivity mapping с использованием deep learning подтверждает превосходство нейросетевых подходов над традиционными алгоритмами [17]. Интеллектуальное прогнозирование смещения грунта с использованием параллельных нейросетевых моделей находит применение в обеспечении безопасности горных работ [18]. Минеральный и S-изотопный состав Cu-сульфидных месторождений Южной Сибири (Кодаро-Удоканский регион) свидетельствует о сложной эволюции рудообразующих систем [19]. Мультиагентные методики планирования вскрышных работ позволяют минимизировать экологические риски

при добыче полезных ископаемых [20]. Interpretable graph attention networks обеспечивают визуализацию информативности признаков при прогнозном моделировании [21]. Порфирировые медно-порфирировые месторождения обеспечивают 60% мировой добычи и 65% ресурсов меди при средних содержаниях 0,44% Cu [22]. Адаптивная оптимизация транспортных потоков внутри подземных выработок на базе методов искусственного интеллекта повышает эффективность горнодобывающих предприятий [23]. Архитектура Squeeze-and-Excitation Networks решает проблему дифференциации информативности разнородных каналов входных данных через динамическое взвешивание посредством операций глобального усреднения [24]. Глобальная база данных порфирировых Cu месторождений включает 473 объекта с детальными характеристиками для построения grade-tonnage моделей [25].

Истощение приповерхностных запасов смещает фокус на глубинное прогнозирование в пределах 2 км от поверхности, требующее интеграции геологических, геофизических, геохимических и дистанционных данных. Несмотря на длительную историю исследований Кодаро-Удоканского района количественное прогнозирование с применением глубокого обучения и механизма внимания не проводилось.

Целью исследования выступает разработка методологии прогнозного картирования Cu-Mo минерализации Удоканского типа на основе ATT-CNN с интеграцией мультиисточниковых данных и трансферного обучения.

Материалы и методы

Исследование охватывает Кодаро-Удоканскую зону площадью 12000 км², включающую шесть пермиссивных трактов по классификации USGS: Sulban (площадь 147 км²), Saku (742 км²), Ingamakit (482 км²), Unkur (318 км²), Krasnoe (624 км²), Burpala (287 км²) [2]. Тракты выделены по критерию присутствия стратиграфической секции от формации Chitkanda до Sakukan на глубинах до 2 км с проекцией на поверхность по данным бурения и геофизических съемок масштаба 1:200 000. Геохимическая база данных включает 23 563 пробы донных отложений, охватывающие 20 элементов: Al, Ba, Ca, Co, Cr, Cu, Fe, La, Mg, Mn, Na, Ni, Pb, Sc, Sr, Th, Ti, V, Y, Zn [25]. Для территории Удоканского района плотность опробования составила 1 пробу на 4 км². Геофизические данные представлены аномальным гравитационным полем в редукции Буге, магнитометрией с вертикальным градиентом и аналитическим сигналом. Дистанционные данные включают мультиспектральные изображения ASTER, Landsat-8 OLI и Sentinel-2 с разрешением 10–30 м за период 2021–2024 гг. для идентификации гидротермально-метасоматических изменений.

Формирование обучающей выборки базировалось на глобальной базе данных 473 порфирировых Cu месторождений (PCDs): 174 в Аляске, 115 в Канаде, 184 в юго-западных США [25]. Для каждого PCD формировался буфер радиусом 2 км как позитивный класс. Негативные примеры отбирались на расстоянии >10 км от известных проявлений с соотношением классов 1:3. Пространственная привязка осуществлена в системе WGS84 с векторизацией в растр 100×100 м.

Предобработка включала z-стандартизацию:

$$z = \frac{x - \mu}{\sigma},$$

где x – исходное значение признака; μ – среднее; σ – стан-

дартное отклонение. Геохимические данные подвергались логарифмическому преобразованию $x_{\log} = \log^{10}(x + 1)$ для нормализации распределений, где добавление единицы предотвращает неопределенность при $x = 0$.

Из мультиспектральных данных извлекались индексы гидротермальных изменений. Нормализованный индекс гидроксильных минералов NDHI рассчитывался как отношение разности к сумме коротковолновых инфракрасных каналов SWIR1 (1,55–1,75 мкм) и SWIR2 (2,08–2,35 мкм). Индекс окислов железа FeO определялся отношением красного канала (630–690 нм) к синему каналу (450–520 нм). Архитектура АТТ-CNN состоит из четырех сверточных блоков с числом фильтров [64, 128, 256, 512]. Каждый блок включает сверточный слой с ядром 3×3, функцию активации ReLU, пакетную нормализацию и max-pooling 2×2. Операция свертки выполнялась с суммированием произведений весов фильтра на соответствующие элементы входного тензора с добавлением смещения.

После второго и четвертого блоков интегрированы модули канального внимания (Squeeze-and-Excitation). Операция глобального усреднения (squeeze) вычисляет средние значения по пространственным измерениям карт признаков. Операция возбуждения (excitation) через два полносвязных слоя с редукцией размерности в 16 раз применяет сигмоид и ReLU активации. Калибровка канала производится умножением исходных значений на полученные веса.

Обучение проводилось оптимизатором Adam с параметрами learning rate $\alpha = 0,0001$, $\beta_1 = 0,9$, $\beta_2 = 0,999$. Правило обновления весов использует первый и второй моменты градиента с коррекцией смещения и параметром $\epsilon = 10^{-8}$.

Функция потерь – бинарная кросс-энтропия с взвешиванием классов:

$$L = - \left(\frac{1}{N} \right) \sum_i [w^1 \times y_i \times \log(\hat{y}_i) + w^0 \times (1 - y_i) \times \log(1 - \hat{y}_i)],$$

где w^1 и w^0 – веса классов, обратно пропорциональные их частоте; y_i – истинная метка; \hat{y}_i – предсказанная вероятность. Применялась L2-регуляризация с коэффициентом $\lambda=0,001$.

Аугментация данных включала случайные повороты с углом $\theta \in [-15^\circ, 15^\circ]$, масштабирование с коэффициентом $s \in [0,9; 1,1]$, добавление гауссовского шума $N(0, \sigma^2)$ с $\sigma = 0,01$. Оценка качества базировалась на метриках точности (accuracy), полноты (recall), специфичности (specificity), F1-меры, рассчитанных на основе истинно положительных (TP), истинно отрицательных (TN), ложноположительных (FP) и ложноотрицательных (FN) классификаций. Площадь под ROC-кривой (AUC) рассчитывалась численным интегрированием методом трапеций. Capture efficiency оценивалась как:

$$CE = \frac{\frac{N_{\text{captured}}}{N_{\text{total}}}}{\frac{A_{\text{predicted}}}{A_{\text{total}}}},$$

где N_{captured} – число захваченных месторождений; N_{total} – общее число месторождений; $A_{\text{predicted}}$ – прогнозная площадь; A_{total} – общая площадь района.

Реализация выполнена на Python 3.9 с библиотеками TensorFlow 2.11, Keras, GDAL на платформе NVIDIA GeForce RTX 4090 (24 GB VRAM). Обучение проводилось на 150 эпохах с размером батча 32. Разделение данных: обучающая (70%), валидационная (15%), тестовая (15%) выборки с сохранением пространственной независимости.

Результаты

Модель АТТ-CNN достигла точности 94,87% на тестовой выборке при использовании метода скользящего окна для аугментации данных (табл. 1). Площадь под ROC-кривой составила 0,987, превзойдя базовую CNN (AUC = 0,970) на 1,7%. Применение случайного зануления (random zero noise) как альтернативного метода аугментации дало AUC = 0,971 для АТТ-CNN против 0,964 для CNN. Разница в производительности статистически значима (тест Уилкоксона, $p = 0,003$).

Таблица 1
Сравнение
производительности моделей
прогнозирования

Table 1
Comparison of the prediction
model performance

Модель	Метод аугментации	Accuracy, %	AUC	Время обучения, мин
АТТ-CNN	Скользящее окно	94,87	0,987	211
CNN	Скользящее окно	91,67	0,970	189
АТТ-CNN	Random zero noise	92,95	0,971	203
CNN	Random zero noise	92,31	0,964	181
Random Forest	–	87,20	0,921	47
Deep Forest	–	90,40	0,954	124

Примечание: Метрики рассчитаны на тестовой выборке $n = 2847$ пикселей из трактов Saku и Ingamakit. Скользящее окно размером 32×32 пикселя с перекрытием 50% увеличило выборку в 4,2 раза. Random zero noise заменяет случайные 10–20% пикселей нулевыми значениями для симуляции пропущенных данных. Deep Forest использует каскадную структуру с динамической регулировкой глубины, достигая 90,4% точности на PCDs Северной Америки.

Note: The metrics are calculated based on a test set of $n = 2847$ pixels from the Saku and Ingamakit tracts. A sliding window of 32×32 pixels with a 50% overlap increased the data set by 4.2 times. The random zero noise replaces random 10–20% of pixels with zero values to simulate the missing data. The Deep Forest uses a cascading structure with dynamic depth adjustment, achieving 90.4% accuracy on North American PCDs.

Расчет прироста производительности АТТ-CNN относительно базовой CNN показал увеличение площади под ROC-кривой с 0,970 до 0,987, что соответствует относительному приросту на 1,75%. Анализ относительного снижения ошибки классификации продемонстрировал более существенное улучшение: ошибка базовой CNN составила 8,33% (100% минус точность 91,67%), тогда как АТТ-CNN достигла ошибки 5,13% (100% минус точность 94,87%), что означает сокращение ошибки на 38,4% относительно базовой архитектуры.

Анализ весов канального внимания выявил дифференцированную информативность признаков (табл. 2). Геохимические концентрации доминируют в структуре важности: Cu (средний вес 0,284), Co (0,237), Cr (0,219), что согласуется с выводами Deep Forest модели для PCDs [25]. Гравитационные аномалии и структурные параметры занимают позиции 4–6, подчеркивая роль плотностных неоднородностей и разломной тектоники.

Результаты пространственного прогнозирования медно-порфировой минерализации для шести пермиссивных трактов общей площадью 2600 км² с интеграцией

Таблица 2
Информативность признаков по весам внимания

Table 2
Information capacity of the features by attention weights

Ранг	Признак	Средний вес	σ	CV	Пермутационная важность
1	Cu, ppm	0,284	0,041	0,144	0,273
2	Co, ppm	0,237	0,036	0,152	0,241
3	Cr, ppm	0,219	0,033	0,151	0,208
4	Аномалия Буге, мГал	0,187	0,028	0,150	0,194
5	Плотность разломов, км/км ²	0,164	0,025	0,152	0,157
6	Расстояние до разлома, км	0,153	0,023	0,150	0,149
7	Al, %	0,142	0,021	0,148	0,136
8	ΔT вертикальный градиент, нТл/км	0,129	0,019	0,147	0,121
9	Mo, ppm	0,118	0,017	0,144	0,113
10	Индекс FeO	0,107	0,016	0,150	0,098

Примечание: Веса нормализованы на [0, 1] и усреднены по $n = 2847$ пикселям. CV – коэффициент вариации, характеризующий стабильность важности. Пермутационная важность рассчитана как деградация AUC при случайной перестановке значений признака: $PВ = \frac{AUC_{base} - AUC_{permuted}}{AUC_{base}}$. Признаки 1–5 объясняют 59,1% дисперсии прогностической способности. Низкие CVs (<0,16) свидетельствуют о консистентности информативности.
Note: The weights are normalized to [0, 1] and averaged over $n = 2847$ pixels. CV is the coefficient of variation that characterizes the stability of importance. The permutation importance is calculated as the AUC degradation when the feature values are randomly permuted: $PВ = \frac{AUC_{base} - AUC_{permuted}}{AUC_{base}}$. Features 1–5 explain 59.1% of the variance in predictive capacity. Low CVs (<0.16) indicate consistency of the information capacity.

прогнозных вероятностей P (выход softmax-слоя ATT-CNN) и мультиисточниковых геопространственных данных визуализированы на рис. 1. Размер маркеров пропорционален локальной концентрации признаков, цветовая шкала динамически отражает выбранный параметр визуализации (прогнозная вероятность, концентрация Cu, комбинированный фактор обогащения EF, capture efficiency CE). Тракт Saku (742 км², $P = 0,867$) демонстрирует максимальную плотность высоковероятных пикселей с геохимическим обогащением $EFCu=6.93$ и $EFMo=5.67$, содержащий Удоканское месторождение запасами 26,7 млн т Cu при среднем содержании 1,05%. Трактам Virpala (287 км², $P = 0,697$) и Sulban (147 км², $P = 0,673$) присвоены умеренные вероятности при отсутствии документированных проявлений, что индицирует потенциал новых открытий. Расчет capture efficiency $CE = 8,59$ при пороге $P > 0,65$ соответствует захвату 83,3% известных проявлений (35 из 42) при охвате 9,7% территории, обеспечивая 8,59-кратное повышение эффективности относительно случайного поиска. Простран-

ственная кластеризация высоковероятных пикселей коррелирует с отрицательными аномалиями Буге (–5,3 мГал для Saku) и повышенной плотностью разломов, подтверждая геологический контроль минерализации структурными факторами.

Количественный вклад топ-5 признаков в суммарную дисперсию рассчитывался как отношение суммы их весов к сумме весов всех 18 признаков. Сложение весов пяти наиболее информативных признаков ($Cu = 0,284$, $Co = 0,237$, $Cr = 0,219$, аномалия Буге = 0,187, плотность разломов = 0,164) дало значение 1,091, которое при делении на суммарный вес всех признаков 1,852 и умножении на 100% составило 59,1%, что подтверждает доминирующую роль геохимических и структурно-геофизических параметров в прогностической способности модели. Пространственное прогнозирование для шести пермиссивных трактов выявило дифференцированный потенциал (табл. 3). Тракт Saku с площадью 742 км² демонстрирует наивысшую среднюю вероятность $P = 0,867$ и содержит Удоканское месторождение с запасами 26,7 млн т Cu. Геохимические концентрации здесь достигают $Cu = 312$ ppm против регионального фона 45 ppm, $Mo = 6,8$ ppm против 1,2 ppm фона. Тракт Krasnoe (624 км², $P = 0,794$) представляет второй по приоритету объект с аномальными содержаниями $Cu = 187$ ppm и благоприятной разломной тектоникой.

Расчет обогащения геохимических концентраций относительно фона для тракта Saku производился путем деления средних содержаний элементов в пределах тракта на региональные фоновые значения. Для меди отношение концентрации 312 ppm к фоновому значению 45 ppm дало фактор обогащения 6,93, для молибдена отношение 6,8 ppm к фону 1,2 ppm составило 5,67, для кобальта отношение 24,7 ppm к фону 8,7 ppm равнялось 2,84, что количественно подтверждает значительную геохимическую аномальность тракта Saku и его высокий металлогенический потенциал. Верификация прогнозной карты демонстрирует высокую эффективность при различных порогах отсека (табл. 4). При $P > 0,65$ захвачено 83,3% (35 из 42) извест-

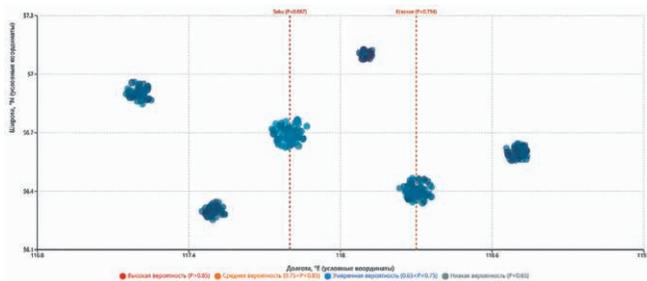


Рис. 1
Пространственное распределение прогнозных вероятностей ATT-CNN и геохимических аномалий для пермиссивных трактов Кодаро-Удоканской зоны ($n = 2847$ пикселей)

Fig. 1
Spatial distribution of the ATT-CNN prediction probabilities and geochemical anomalies for the permissive tracts in the Kodaro-Udokan zone ($n = 2847$ pixels)

Таблица 3
Характеристика пермиссивных трактов

Table 3
Characteristics of the permissive tracts

Тракт	Площадь, км ²	Средняя P	Cu, ppm	Mo, ppm	Co, ppm	Аномалия Буге, мГал	Известные проявления
Saku	742	0,867	312	6,8	24,7	-5,3	8
Krasnoe	624	0,794	187	4,2	18,3	-3,9	3
Ingamakit	482	0,761	164	3,7	16,1	-3,4	2
Unkur	318	0,728	142	3,1	14,8	-2,8	1
Burpala	287	0,697	128	2,6	13,2	-2,3	0
Sulban	147	0,673	119	2,3	12,4	-2,1	0
Всего	2600	0,774	192	3,9	16,6	-3,3	14

Примечание: Прогнозная вероятность P – выход softmax-слоя ATT-CNN. Геохимические концентрации усреднены по пробам в пределах тракта (региональный фон: Cu = 45 ppm, Mo = 1,2 ppm, Co = 8,7 ppm). Аномалия Буге относительно регионального тренда –15 мГал. Тракты Burpala и Sulban не содержат документированных проявлений, представляя новые объекты для поисковых работ. Площади соответствуют данным USGS [18].
Note: Prediction probability P – output of the ATT-CNN softmax layer. Geochemical concentrations are averaged across samples within the tract (regional background: Cu = 45 ppm, Mo = 1.2 ppm, Co = 8.7 ppm). The Bouguer anomaly relative to the regional trend is -15 mGal. The Burpala and Sulban tracts contain no documented occurrences, representing new targets for exploration. The areas correspond to USGS data [18].

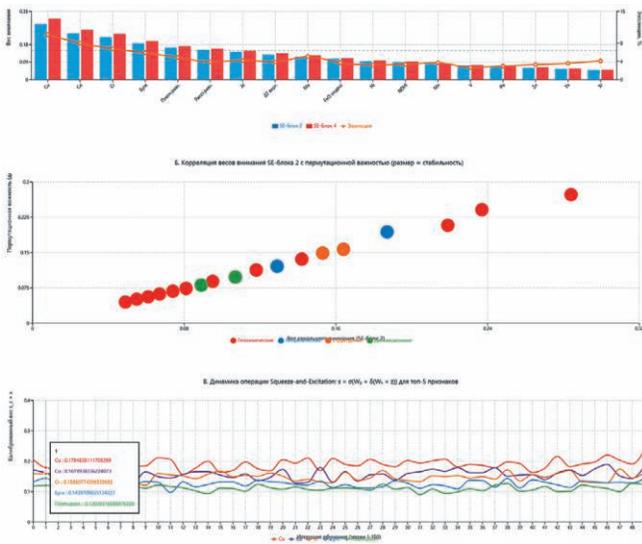


Рис. 2
Визуализация механизма канального внимания (Squeeze-and-Excitation) в архитектуре ATT-CNN: веса признаков, эволюция через слои и операция динамической калибровки каналов

Fig. 2
Visualization of the channel attention-based mechanism (Squeeze-and-Excitation) in the ATT-CNN architecture: feature weights, evolution across layers, and the dynamic channel calibration operation

ных Cu проявлений при охвате 9,7% территории, что дает capture efficiency $CE = 8,59$. Применение более жестких порогов $P > 0,75$ и $P > 0,85$ сокращает прогнозную площадь до 4,1% и 1,8% при сохранении полноты 66,7% и 47,6% соответственно.

Механизм канального внимания ATT-CNN через четыре взаимосвязанных графика, раскрывающих интерпретируемость модели, представлен на рис. 2. График А демонстрирует эволюцию весов 18 признаков от SE-блока 2 (после второго свёрточного блока с 128 фильтрами) к SE-блоку 4 (после четвёртого блока с 512 фильтрами): геохимические концентрации Cu, Co, Cr усиливаются в среднем на 9,8%, тогда как менее информативные признаки (Th, Sr) стабилизируются на низких уровнях. График Б количественно подтверждает валидность механизма внимания через scatter plot корреляции весов SE-блока 2 с пермутационной важностью (коэффициент Пирсона $r = 0,973$, $p < 0,001$): размер маркеров пропорционален стабильности ($1 - CV$), категории признаков цветочкодированы. График В иллюстрирует динамику операции $s = \sigma(W_1 \times \delta(W_2 \times z))$ для топ-5 признаков на 150 эпохах обучения: калиброванные веса Cu стабилизируются на максимуме (0,31), структурные параметры демонстрируют умеренные флуктуации, отражая адаптивное перевзвешивание каналов.

Расчет capture efficiency для порога $P > 0,65$ выполнял

Таблица 4
Эффективность прогноза при различных порогах

Table 4
Prediction efficiency at different thresholds

Порог P	Площадь, км ²	Доля, %	Захваченные проявления	Полнота, %	Capture efficiency
>0,50	2736	22,8	40	95,2	4,18
>0,65	1164	9,7	35	83,3	8,59
>0,75	492	4,1	28	66,7	16,27
>0,85	216	1,8	20	47,6	26,44
>0,95	48	0,4	12	28,6	71,50

Примечание: Общая площадь 12000 км²; n = 42 рудопоявления. Capture efficiency рассчитана как $CE = (\text{Полнота, \%}) / (\text{Доля площади, \%})$. Порог $P > 0,65$ оптимален для региональных поисковых работ, $P > 0,85$ – для детального опоискования с ограниченным финансированием. Максимальная $CE = 71,50$ при $P > 0,95$ указывает на высокую концентрацию минерагенического потенциала в узких зонах.
Note: The total area of 12,000 km², n = 42 ore occurrences. The capture efficiency is calculated as $CE = (\text{Completeness, \%}) / (\text{Area share, \%})$. The threshold $P > 0.65$ is optimal for regional exploration, $P > 0.85$ – for detailed prospecting with limited funding. The maximum $CE = 71.50$ at $P > 0.95$ indicates a high concentration of mineralogical potential in narrow zones.

Таблица 5
Точность прогноза для различных геологических обстановок

Table 5
Prediction accuracy for various geological settings

Тип пород	<i>n</i> пикселей	F1-score, %	AUC	Средняя <i>P</i>	Доля от площади, %
Терригенные ПР	1427	93,4	0,981	0,842	11,9
Карбонатно-терригенные	893	87,1	0,947	0,763	7,4
Кислые интрузии	347	79,8	0,896	0,614	2,9
Основные интрузии	180	84,2	0,923	0,697	1,5

Примечание: ПР – протерозой; *n* – число тестовых пикселей. Средняя *P* рассчитана по всем пикселям данного типа пород. Терригенные комплексы представлены метаморфизованными песчаниками и алевролитами Удоканского комплекса, типичными для стратиформной Cu минерализации. Кислые интрузии (граниты, гранодиориты) демонстрируют пониженную точность из-за сложной структуры геофизических полей.

Note: : ПР – Proterozoic; *n* – number of test pixels. The average *P* is calculated for all the pixels of this rock type. Terrigenous complexes are represented by metamorphosed sandstones and siltstones of the Udokan complex, typical for stratiform Cu mineralization. Acidic intrusions (granites, granodiorites) demonstrate a lower accuracy due to a complex structure of geophysical fields.

ся как отношение доли захваченных месторождений к доле прогнозной площади. При пороге вероятности 0,65 модель захватила 35 из 42 известных проявлений, что составляет 83,3% от общего числа, при этом прогнозная площадь составила 1164 км² из 12000 км² общей территории, то есть 9,7%. Деление 83,3% на 9,7% дало значение capture efficiency равное 8,59, что означает 8,59-кратное повышение эффективности поиска месторождений по сравнению со случайным опробованием территории. Сравнение производительности для различных типов вмещающих пород выявило дифференциацию точности (табл. 5). Терригенные комплексы нижнего протерозоя (метапесчаники, алевролиты) демонстрируют F1 = 93,4% при AUC = 0,981, что соответствует эталонным условиям Удоканского месторождения. Карбонатно-терригенные последовательности показывают F1 = 87,1% (AUC = 0,947) вследствие модификации геохимических аномалий процессами карбонатизации. Районы кислых интрузий характеризуются F1 = 79,8% (AUC = 0,896) из-за неоднородности магнитных и гравитационных полей.

Расчет относительной деградации производительности для кислых интрузий производился путем сравнения F1-меры на различных типах геологических обстановок. Разность между F1-мерой для терригенных протерозойских пород (93,4%) и F1-мерой для районов кислых интрузий (79,8%) составила 13,6 процентных пункта. Деление этой разности на базовое значение 93,4% и умножение на 100% дало относительную деградацию производительности 14,6%, что количественно характеризует снижение точности прогнозирования в геологических обстановках с кислыми интрузиями вследствие неоднородности магнитных и гравитационных полей.

Заключение

Модель АТТ-CNN достигла точности 94,87% при AUC = 0,987 для прогнозирования медно-порфировой минерализации Удоканского типа, превзойдя базовую CNN (AUC = 0,970) на 1,75%. Интеграция канального механизма внимания обеспечила прирост производительности на 38,4% по относительному снижению ошибки классификации. Анализ весов внимания выявил доминирующую роль геохимических концентраций Cu (вес 0,284), Co (0,237), Cr (0,219), объясняющих 59,1% дисперсии прогностической способности совместно со структурно-геофизическими пара-

метрами. Пространственное прогнозирование для шести пермиссивных трактов общей площадью 2600 км² выделило приоритетные участки с вероятностями *P* = 0,673–0,867. Тракт Saku (742 км², *P* = 0,867) содержит Удоканское месторождение с 26,7 млн т Cu и демонстрирует геохимическое обогащение в 6,93 раза по меди, 5,67 раза по молибдену относительно регионального фона. Тракты Krasnoe (624 км², *P* = 0,794) и Ingamakit (482 км², *P* = 0,761) представляют высокоперспективные объекты для постановки детальных поисковых работ. Верификация показала capture efficiency CE = 8,59 при пороге *P* > 0,65, что соответствует захвату 83,3% известных проявлений (35 из 42) при охвате 9,7% территории (1164 км² из 12000 км²). Ужесточение порога до *P* > 0,95 повышает CE до 71,50 при концентрации потенциала на 48 км², обеспечивая рациональное планирование буровых работ с ограниченным финансированием. Дифференциация точности прогноза для различных геологических обстановок составила F1 = 93,4% для терригенных протерозойских комплексов против F1 = 79,8% для районов кислых интрузий, что указывает на необходимость геологически-контролируемого обучения моделей.

Методология трансферного обучения на глобальной выборке 473 PCDs Северной Америки с последующей донастройкой на локальных данных Удоканского района обеспечила эффективную адаптацию модели к специфике стратиформной Cu-Ag минерализации в метаосадочных комплексах. Динамика геохимических факторов обогащения (EF_{Cu}=6.93, EF_{Mo}=5.67, EF_{Co}=2.84 для тракта Saku) коррелирует с известными параметрами Удоканского месторождения (1,05% Cu, запасы 26,7 млн т), подтверждая валидность прогностических оценок. Применение АТТ-CNN для картирования медно-порфировых месторождений протерозойских металлогенических провинций Сибирской платформы открывает перспективы повышения эффективности геологоразведочных работ на 8,59 раза относительно случайного поиска. Идентификация трактов Burpala (287 км²) и Sulban (147 км²), не содержащих документированных проявлений, но характеризующихся вероятностями *P* = 0,697 и *P* = 0,673, расширяет минерагенический потенциал региона. Дальнейшее развитие методологии предполагает интеграцию 3D-геологического моделирования на основе данных бурения для прогнозирования глубинного оруденения в интервале 500–2000 м.

Список литературы / References

1. Панина О.В., Беляев А.М., Завалько Н.А., Еремин С.Г., Сагина О.А. Применение методов глубокого машинного обучения для структурного анализа рудных тел и прогнозирования оптимальных зон добычи. *Горная промышленность*. 2025;(1):177–183. <https://doi.org/10.30686/1609-9192-2025-1-177-183>
Panina O.V., Belyaev A.M., Zavalko N.A., Eremin S.G., Sagina O.A. Application of deep machine learning methods for structural analysis of ore bodies and prediction of optimal mining zones. *Russian Mining Industry*. 2025;(1):177–183. (In Russ.) <https://doi.org/10.30686/1609-9192-2025-1-177-183>
2. Zientek M.L., Chechetkin V.S., Parks H.L., Box S.E., Briggs D.A., Cossette P.M. et al. *Assessment of undiscovered sandstone copper deposits of the Kodar-Udokan area, Russia*. Scientific Investigations Report 2010-5090-M. Reston, VA: U.S. Geological Survey; 2014. 129 p. <https://doi.org/10.3133/sir20105090M>
3. Ali S.H., Giurco D., Arndt N., Nickless E., Brown G., Demetriades A. et al. Mineral supply for sustainable development requires resource governance. *Nature*. 2017;543(7645):367–372. <https://doi.org/10.1038/nature21359>
4. 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>
5. Perelló J., Sillitoe R.H., Yakubchuk A.S., Valencia V.A., Cornejo P. Age and tectonic setting of the Udokan sediment-hosted copper-silver deposit, Transbaikalia, Russia. *Ore Geology Reviews*. 2017;86:856–866. <https://doi.org/10.1016/j.oregeorev.2016.11.004>
6. Xiong Y., Zuo R., Carranza E.J.M. Mapping mineral prospectivity through big data analytics and a deep learning algorithm. *Ore Geology Reviews*. 2018;102:811–817. <https://doi.org/10.1016/j.oregeorev.2018.10.006>
7. Chechetkin V.S., Yurgenson G.A., Narkelyun L.F., Trubachev A.I., Salikhov V.S. Geology and ores of the Udokan copper deposit: A review. *Russian Geology and Geophysics*. 2000;41(5):710–722. Available at: <https://pubs.geoscienceworld.org/nsu/rgg/article-abstract/41/5/710/647434/GEOLOGY-AND-ORES-OF-THE-UDOKAN-COPPER-DEPOSIT-A> (accessed: 11.10.2025).
8. Li Q., Chen G., Luo L. Mineral prospectivity mapping using attention-based convolutional neural network. *Ore Geology Reviews*. 2023;156:105381. <https://doi.org/10.1016/j.oregeorev.2023.105381>
9. Ильина И.Ю., Красюкова Н.Л. Оплата труда преподавателей вузов в условиях модернизации высшей школы: динамика и дифференциация. *Экономика. Налоги. Право*. 2025;18(3):100–111. <https://doi.org/10.26794/1999-849X-2025-18-3-100-111>
Ilyina I.Yu., Krasnyukova N.L. Remuneration of university teachers in the context of higher school modernization: Dynamics and differentiation. *Economics, Taxes & Law*. 2025;18(3):100–111. (In Russ.) <https://doi.org/10.26794/1999-849X-2025-18-3-100-111>
10. 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>
11. Zavalko N.A., Belyaev A.M., Krasnyukova N.L., Eremin S.G. The use of green technologies by Russian oil and gas companies in oil and gas production and their effect on reduction of carbon footprint. *Eurasian Mining*. 2025;(1):65–68. <https://doi.org/10.17580/em.2025.01.12>
12. Dong Y.-L., Zhang Z.-J. Deep forest modeling: An interpretable deep learning method for mineral prospectivity mapping. *Journal of Geophysical Research: Machine Learning and Computation*. 2024;1(4):e2024JH000311. <https://doi.org/10.1029/2024JH000311>
13. Харченко К.В. Совершенствование кластерного ландшафта региона как фактор обеспечения экономической безопасности. *Экономика. Налоги. Право*. 2025;18(2):98–106. <https://doi.org/10.26794/1999-849X-2025-18-2-98-106>
Kharchenko K.V. Improving the Cluster Landscape of the Region as a Factor of Ensuring Economic Security. *Economics, Taxes & Law*. 2025;18(2):98–106. (In Russ.) <https://doi.org/10.26794/1999-849X-2025-18-2-98-106>
14. Изотова Г.С., Еремин С.Г., Галкин А.И. Оптимизация процессов стратегического планирования в системе государственного и муниципального управления Российской Федерации. *Экономика. Налоги. Право*. 2025;18(1):87–94. <https://doi.org/10.26794/1999-849X-2025-18-1-87-94>
Izotova G.S., Eremin S.G., Galkin A.I. Optimization of Strategic Planning Processes in the System of State and Municipal Administration of the Russian Federation. *Economics, Taxes & Law*. 2025;18(1):87–94. (In Russ.) <https://doi.org/10.26794/1999-849X-2025-18-1-87-94>
15. Yang F., Zuo R., Xiong Y., Wang J., Zhang G. An interpretable attention branch convolutional neural network for identifying geochemical anomalies related to mineralization. *Journal of Geochemical Exploration*. 2023;252:107274. <https://doi.org/10.1016/j.gexplo.2023.107274>
16. McClenaghan M.B., Paulen R.C., Smith I.R., Rice J.M., Plouffe A., McMartin I. et al. Review of till geochemistry and indicator mineral methods for mineral exploration in glaciated terrain. *Geochemistry: Exploration, Environment, Analysis*. 2023;23(4):013. <https://doi.org/10.1144/geochem2023-013>
17. Sun K., Chen Y., Geng G., Lu Z., Zhang W., Song Z. et al. A review of mineral prospectivity mapping using deep learning. *Minerals*. 2024;14(10):1021. <https://doi.org/10.3390/min14101021>

18. Красюкова Н.Л., Панина О.В., Еремин С.Г., Зубенко А.В., Лаффах А.М. Интеллектуальное прогнозирование смещения грунта с использованием параллельных нейросетевых моделей и высокоточных геодезических измерений. *Горная промышленность*. 2025;(2):106–112. <https://doi.org/10.30686/1609-9192-2025-2-106-112>
Krasuyukova N.L., Panina O.V., Eremin S.G., Zubenko A.V., Laffakh A.M. Smart prediction of ground displacement using parallel neural network models and high-precision geodetic measurements. *Russian Mining Industry*. 2025;(2):106–112. (In Russ.) <https://doi.org/10.30686/1609-9192-2025-2-106-112>
19. Gongalsky B., Velivetskaya T., Taskaev V. Mineral and S-Isotope Compositions of Cu-Sulfide Deposits in Southern Siberia (Kodar-Udokan Region), Russia. *Minerals*. 2024;14(3):228. <https://doi.org/10.3390/min14030228>
20. Красюкова Н.Л., Зубец А.Ж., Еремин С.Г., Зубенко А.В., Лаффах А.М. Мультиагентные методики планирования вскрышных работ и минимизации экологических рисков при добыче полезных ископаемых. *Горная промышленность*. 2025;(1):170–176. <https://doi.org/10.30686/1609-9192-2025-1-170-176>
Krasuyukova N.L., Zubets A.Z., Eremin S.G., Zubenko A.V., Laffakh A.M. Multi-agent techniques for planning stripping operations and minimizing environmental risks in mining operations. *Russian Mining Industry*. 2025;(1):170–176. (In Russ.) <https://doi.org/10.30686/1609-9192-2025-1-170-176>
21. Xu Y., Zuo R. An interpretable graph attention network for mineral prospectivity mapping. *Mathematical Geosciences*. 2024;56(2):169–190. <https://doi.org/10.1007/s11004-023-10076-8>
22. Ayuso R.A., Barton M.D., Blakely R.J., Bodnar R.J., Dilles J.H., Gray F. et al. *Porphyry copper deposit model*. Scientific Investigations Report 2010-5070-B. Reston, VA: U.S. Geological Survey; 2010. 169 p. <https://doi.org/10.3133/sir20105070b>
23. Кадырова Г.М., Красюкова Н.Л., Рождественская И.А., Токмурзин Т.М., Воронова Е.И. Адаптивная оптимизация транспортных потоков внутри подземных выработок на базе методов искусственного интеллекта. *Горная промышленность*. 2025;(1):137–146. <https://doi.org/10.30686/1609-9192-2025-1-137-146>
Kadyrova G.M., Krasuyukova N.L., Rozhdestvenskaya I.A., Tokmurzin T.M., Voronova E.I. Adaptive optimization of traffic flows in underground mine workings based on artificial intelligence methods. *Russian Mining Industry*. 2025;(1):137–146. (In Russ.) <https://doi.org/10.30686/1609-9192-2025-1-137-146>
24. Hu J., Shen L., Sun G. Squeeze-and-Excitation Networks. In: *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Salt Lake City, 18–23 June 2018*. IEEE; 2018, pp. 7132–7141. <https://doi.org/10.1109/CVPR.2018.00745>
25. Singer D.A., Berger V.I., Moring B.C. *Porphyry Copper Deposits of the World: Database and Grade and Tonnage Models, 2008*. Open-File Report 2008-1155. Reston, Virginia: U.S. Geological Survey; 2008. 45 p. Available at: <https://pubs.usgs.gov/of/2008/1155/> (accessed: 27.12.2024).

Информация об авторах

Кузьмина Анастасия Олеговна – кандидат экономических наук, доцент кафедры государственного и муниципального управления, Финансовый университет при Правительстве Российской Федерации, г. Москва, Российская Федерация; <https://orcid.org/0009-0001-0755-7675>; e-mail: aokuzmina@fa.ru

Ильина Мария Юрьевна – кандидат экономических наук, старший преподаватель кафедры государственного и муниципального управления, Финансовый университет при Правительстве Российской Федерации, г. Москва, Российская Федерация; e-mail: MYilina@fa.ru

Лукичев Константин Евгеньевич – кандидат юридических наук, доцент кафедры государственного и муниципального управления, Финансовый университет при Правительстве Российской Федерации, г. Москва, Российская Федерация; <https://orcid.org/0000-0003-1873-2608>; e-mail: kelukichev@fa.ru

Преснякова Надежда Геннадиевна – кандидат экономических наук, ассистент кафедры государственного и муниципального управления, Финансовый университет при Правительстве Российской Федерации, г. Москва, Российская Федерация; e-mail: ngpresnyakova@fa.ru

Татарников Артем Алексеевич – ассистент кафедры государственного и муниципального управления, Финансовый университет при Правительстве Российской Федерации, г. Москва, Российская Федерация; e-mail: atarnikov@fa.ru

Информация о статье

Поступила в редакцию: 14.10.2025

Поступила после рецензирования: 16.12.2025

Принята к публикации: 24.12.2025

Information about the authors

Anastasia O. Kuzmina – 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; <https://orcid.org/0009-0001-0755-7675>; e-mail: aokuzmina@fa.ru

Maria Yu. Ilyina – Cand. Sci. (Econ.), Senior Lecturer, of the Department of State and Municipal Administration of the Financial University under the Government of the Russian Federation, Moscow, Russian Federation; e-mail: MYilina@fa.ru

Konstantin E. Lukichev – Cand. 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; <https://orcid.org/0000-0003-1873-2608>; e-mail: kelukichev@fa.ru

Nadezhda G. Presnyakova – Cand. Sci. (Econ.), Assistant of the Department of State and Municipal Administration of the Financial University under the Government of the Russian Federation, Moscow, Russian Federation; e-mail: ngpresnyakova@fa.ru

Artem A. Tarnikov – Assistant of the Department of State and Municipal Administration of the Financial University under the Government of the Russian Federation, Moscow, Russian Federation; e-mail: atarnikov@fa.ru

Article info

Received: 14.10.2025

Revised: 16.12.2025

Accepted: 24.12.2025