

Автоматизированное картирование металлотектов с использованием методов глубокого машинного обучения

В рамках данной статьи выполнен краткий обзор теории нейросетевых методов распознавания образов, рассмотрены особенности применения методов глубокого машинного обучения при интерпретации комплексных геолого-геофизических данных и возможности их использования для решения прогнозных задач. Предложена и на примере выделения золоторудных объектов Центрально-Колымского района продемонстрирована методика нейросетевого прогноза полезных ископаемых (ПИ) на базе априорного физико-геологического моделирования путём автоматизированного картирования геологических факторов контроля оруденения.

Ключевые слова: машинное обучение, искусственные нейронные сети, распознавание образов, комплексирование геофизических данных, прогноз оруденения, золоторудные месторождения, Центрально-Колымский регион.

КАРАМЫШЕВ АНДРЕЙ ВИКТОРОВИЧ, геофизик 1 категории, Andrey_Karamyshev@vsegei.ru

ФГБУ «Всероссийский научно-исследовательский геологический институт имени А. П. Карпинского», г. Санкт-Петербург

Automated mapping of metallotects with the use of deep machine learning methods

A. V. KARAMYSHEV

Federal State Budgetary Institution "All-Russian Research Geological Institute of A. P. Karpinsky", St. Petersburg

This article provides a brief overview of the theory of neural network methods of pattern recognition. It considers the features of using deep machine learning methods in interpreting complex geological and geophysical data and the possibilities of using them to solve forecasting problems. A method for neural network forecasting of ore mineralization, based on a priori physical-geological modeling by automated mapping of geological ore control factors, is proposed. The method is demonstrated on the example of identifying gold ore deposits in the Central Kolyma region.

Key words: machine learning, artificial neural networks, pattern recognition, geophysical data integration, mineralization forecast, gold deposits, Central Kolyma region.

Последнее десятилетие отмечено повсеместным распространением алгоритмов машинного обучения и, в частности, компьютерного зрения как универсального инструмента, дополняющего и заменяющего человеческий опыт при решении теоретических и прикладных задач в самых разных областях науки и техники. Особое внимание при этом уделяется подклассу методов глубокого

машинного обучения (МО), работающих с так называемыми «глубокими», то есть многослойными нейросетевыми моделями, используемыми для создания модельных абстракций высокого уровня на основе частных примеров без явного программирования. Искусственные нейронные сети (ИНС) – это математические модели, в той или иной степени имитирующие процессы обработки информации

нервной системой живого организма. В случае компьютерного зрения чаще всего речь идёт о выделении, отслеживании и (или) классификации объектов на цифровых снимках и видеозаписях, что нашло широкое практическое применение в ряде сфер: от уже повсеместного распознавания лиц в охранных системах и персональных устройствах до обработки данных в военной и космической отраслях. Однако алгоритмы распознавания не ограничиваются только работой с визуальными образами. Аналогичным способом структуры могут быть выявлены в любых типах пространственно представимых данных: двумерных снимках и объёмных моделях в различных спектральных диапазонах, физических полях, картах и моделях распределения составов, свойств и др.

В последнее время всё большее значение алгоритмы распознавания приобретают и в различных отраслях геологической науки. В качестве одной из перспективных областей их применения рассматриваются задачи автоматического распознавания элементов геологического строения территории и локализации в её пределах вероятных рудных объектов при помощи комплексного анализа геонаучных данных на уровне, сопоставимом или даже превышающем возможности геолога-интерпретатора. И именно глубокие нейросетевые решения представляются в этой области одними из наиболее перспективных.

Концепция машинного обучения возникла ещё в середине XX в., когда на стыке формальной логики, кибернетики и нейрофизиологии предпринимаются первые попытки математического описания принципов работы нейронно-синаптических систем естественного мозга. Так, в работе 1943 г. «Логическое исчисление идей, относящихся к нервной активности» У. МакКаллока и У. Питтса [18] предлагается первая простейшая дискретно-логическая модель нейрона. Дальнейшее развитие данная концепция получила в работах американского нейрофизиолога Фрэнка Розенблатта. Им была предложена схема «перцептрона» [23] – системы распознавания образов с механизмом обучения, основанным на итерационном изменении синаптических весов в зависимости от выходного значения. С математической точки зрения перцептрон представляет собой просто способ решения систем уравнений с большим числом неизвестных коэффициентов. Принципиальная возможность аппроксимаций с его помощью зависимостей из предметной области следует

из теоремы Колмогорова-Арнольда, обосновывающей представимость любой многомерной непрерывной функции в виде суперпозиции непрерывных функций одной переменной. Доказанная же Розенблаттом теорема сходимости перцептрона демонстрирует, что данный метод, независимо от начального состояния сети и последовательности входных стимулов, всегда приведёт к достижению решения за конечный промежуток времени [22].

Несмотря на то, что в теории перцептрон не имеет функциональных преимуществ над аналитическими методами, с технической точки зрения подбор коэффициентов линейных уравнений несоизмеримо более прост в сравнении с решением уравнений классической статистики. Основным препятствием здесь становится потребность в чрезмерно больших ресурсах времени и памяти. Однако с развитием вычислительной техники значимость этой проблемы постепенно снижалась. Начало XXI в. ознаменовалось невероятным всплеском интереса к нейросетевым методам. К тому моменту уже была разработана достаточная теоретическая база. Были спроектированы многослойные сети, качественно превосходящие ранние наработки. Начались исследования в новой области – свёрточных нейронных сетей (СНС). Последние вместо полного набора связей между слоями используют небольшую матрицу весов, играющую роль оконного фильтра, выделяющего не отдельные значения, а характерные структуры во входных данных. В совокупности с повышенной скоростью обучения за счёт существенно меньшего числа настраиваемых коэффициентов это делает свёрточные нейросети одним из лучших алгоритмов для работы с цифровыми изображениями и другими типами пространственно представимых данных. Параллельно разрабатывались более эффективные нелинейные функции активации нейронов, новые методы оценки качества обучения и оптимизации сети. Возникла сама концепция глубокого обучения (англ. Deep learning), подразумевающая совокупность методов машинного обучения, преследующих цели создания адаптивных нейросетей, которые направлены не на решение одной конкретной задачи, а на реализацию определённой технологии, применимой к целому классу задач. На практике это достигается путём увеличения числа скрытых слоёв, то есть сложности или «глубины» нейросети, что во многом стало возможным благодаря изобретению в середине 1970-х годов метода обратного распространения

ошибки, позволяющего осуществлять оптимизацию коэффициентов всей сети на основании выходных значений только последнего слоя. Современная реализация данного метода, применяемая для эффективной тернировки глубоких слоёв нейронной сети, была предложена в 2006 г. Дж. Хинтоном из университета Торонто. Знаковым примером применения глубокого обучения можно считать опубликованную в 1989 г. работу Яна Лекуна по распознаванию рукописных символов [14]. В ней была предложена архитектура свёрточной нейросети с обратным распространением ошибки, получившая название LeNet-5. Однако, несмотря на неплохие результаты распознавания, концепция поначалу не снискала популярности по причине недостатка мощности вычислительного оборудования, в первую очередь – графических процессоров.

В геологических науках первые серьёзные примеры применения нейросетевых технологий и машинного зрения также относятся к концу 1980-х годов. В статье Г. Бонем-Картера (1989) [4] вводится концепция картирования минерального потенциала (англ. mineral prospectivity mapping) как статистического метода интеграции и интерпретации пространственных закономерностей в геонаучных данных. На практике это сводится к подбору алгоритма анализа данных и выводу так называемой «картировочной функции», то есть закона, связывающего физические объекты и их отражение в признаковом пространстве. Нейросетевые методы при решении подобных задач сначала уступали первенство менее ресурсозатратным альтернативным решениям – методам опорных векторов, логистической регрессии, дискриминантного анализа и нечёткой логики. Однако параллельно продолжались эксперименты по построению и обучению полносвязных многослойных нейронных сетей и вскоре были представлены первые решения задач классификации рудных объектов и оценки минеральной перспективности на основе наборов ГИС-данных [11, 24]. Ряд аналитических исследований [6, 12] показал более высокую по сравнению с аналогами точность нейросетевых методов в задачах геологического прогноза, имеющих дело с многомерным признаковым пространством и нелинейными связями между признаками и метками. Отдельные ранние примеры практического использования нейронных сетей для оценки минерального потенциала и геологического картирования можно встретить уже в работах 2000-х годов [3, 20]. При этом сам

по себе формализованный прогноз ПИ в силу объективной сложности верификации результатов по сравнению, например, с распознаванием изображений с недоверием воспринимался научным сообществом и до недавнего времени оставался чисто академической областью.

Переломный момент в развитии методов глубокого обучения наступил в 2012 г., когда свёрточная нейронная сеть AlexNet [13], представляющая углублённую и расширенную версию упомянутой LeNet-5, впервые превзошла человека по скорости визуального распознавания образов. С этого момента глубокое обучение перестало быть исключительно экспериментальной сферой, а стало рабочим инструментом решения практических повседневных задач. Последовавший всплеск интереса к нейросетевым методам не обошёл стороной и геологические науки. Число статей на соответствующую тематику с упоминаниями машинного обучения за последние 10 лет выросло практически на порядок [9].

Искусственная нейронная сеть представляет собой логическую структуру, состоящую из особым образом упорядоченных и взаимосвязанных элементарных процессоров. Базовый элемент нейросети – искусственный нейрон – по существу представляет собой взвешенный сумматор с n входов и единственным выходом. Его выходное значение определяется так называемой «активационной функцией» $f(s)$, где $s = \sum_{i=1}^n \mathbf{W}_i \mathbf{x}_i + \mathbf{b}_0$.

Здесь \mathbf{W}_i и \mathbf{x}_i – соответственно сигналы на входах нейрона и веса входов, а \mathbf{b}_0 – смещение – аддитивный параметр, корректирующий значение результирующей суммы входов и тем самым задающий порог чувствительности нейрона. В качестве активационной чаще всего выбирается монотонно возрастающая функция с ограниченным диапазоном значений, например [0,1] или [-1,1], такая как, например, сигмоида или гиперболический тангенс. Единичные нейроны организуются в слои, соединённые системой взвешенных связей. Слой, в котором каждый нейрон соединён со всеми нейронами предыдущего, называется полносвязным как и сеть, построенная из таких слоёв.

Результат работы подобного слоя может быть представлен в виде:

$$\mathbf{x}^{(1)} = f(\mathbf{W}\mathbf{x}^{(0)} + \mathbf{b}), \quad (1)$$

$$\text{где } \mathbf{x}^{(0)} = \begin{bmatrix} \mathbf{x}_0^{(0)} \\ \mathbf{x}_1^{(0)} \\ \vdots \\ \mathbf{x}_i^{(0)} \end{bmatrix} \text{ – вектор входных значений,}$$

$$\mathbf{W} = \begin{bmatrix} \mathbf{W}_{0,0} \cdots \mathbf{W}_{0,i} \\ \vdots \\ \mathbf{W}_{j,0} \cdots \mathbf{W}_{j,i} \end{bmatrix} - \text{матрица весов,}$$

$$\mathbf{b} = \begin{bmatrix} \mathbf{b}_0 \\ \mathbf{b}_1 \\ \vdots \\ \mathbf{b}_i \end{bmatrix} - \text{вектор смещений,}$$

$$\mathbf{x}^{(1)} = \begin{bmatrix} \mathbf{x}_0^{(1)} \\ \mathbf{x}_1^{(1)} \\ \vdots \\ \mathbf{x}_j^{(1)} \end{bmatrix} - \text{вектор выходных значений.}$$

В общем случае ИНС состоит из входного, выходного и системы скрытых слоёв. Сеть с более чем одним скрытым слоем называется глубокой. Число нейронов входного слоя зависит от геометрии входных данных. Так, если речь идёт о распознавании образов и обучающий пример представляет собой массив размерами (m, n, k) , то входной слой будет насчитывать $m \cdot n$ нейронов по числу векторов признаков длины k .

В отдельный большой класс архитектур, изначально ориентированных на работу с цифровыми изображениями и другими пространственно представимыми данными, выделяются ранее упомянутые свёрточные нейронные сети. Их специфика заключается в использовании особых пространственных фильтров – ядер свёртки – скользящих окон, связывающих каждый нейрон со сравнительно небольшой группой смежных нейронов предыдущего слоя через набор весовых коэффициентов. Слой в этом случае представим в виде пакета двумерных матриц, каждая из которых соответствует определённому ядру свёртки. Очевидно, что в этом случае даже при использовании значительного числа фильтров общее количество взвешенных связей будет меньше, чем у полносвязного слоя. Свёрточные слои в СНС обычно чередуются со слоями подвыборки или субдискретизации (англ. pooling layer), выполняющими уплотнение карт признаков путём сжатия группы значений в одно через нелинейное преобразование, например, функцию максимума. Это позволяет дополнительно уменьшить число настраиваемых параметров сети и устранить высокочастотные шумы.

В целом, подобный принцип организации нейросети приводит к тому, что вместо попиксельного «запоминания» обучающих примеров, как в случае перцептрона, она кодирует в ядрах свёртки характерные элементы и структуры данных,

такие как, например, границы. При этом с увеличением глубины сети растёт степень обобщения информации и извлекаются всё более высокоуровневые признаки. Это делает СНС более устойчивыми к вариациям и искажениям входных данных. Кроме того, значительное уменьшение числа параметров в сравнении с полносвязными сетями даёт заметный выигрыш в производительности даже для сравнительно более глубоких архитектур.

В общем случае обучение нейронной сети с учителем можно рассматривать как задачу оптимизации. Она сводится к настройке параметров сети – весов и смещений – в целях минимизации значения некой функции, характеризующей качество работы алгоритма по величине расхождения выходных и целевых значений и называемой функцией потерь.

Пусть:

\mathbf{X}_i^{Train} для $i = 1::N$ – набор из N обучающих примеров,

\mathbf{Y}^{Train} – набор меток,

$f(\theta; \mathbf{X}^{Train})$ – интерпретирующая функция, где θ – совокупность настраиваемых параметров ИНС.

Тогда для оптимально обученной модели:

$$\theta^* = \operatorname{argmin} L(\mathbf{Y}^{Train} - f(\theta; \mathbf{X}^{Train})), \quad (2)$$

где L – функция потерь,

$$\mathbf{Y}^{Predict} = f(\theta; \mathbf{X}^{Predict}) \quad (3)$$

– интерпретация другого аналогичного набора данных $\mathbf{X}^{Predict}$ [10].

Наиболее распространённым подходом к решению такой задачи выступают различные вариации метода градиентного спуска. Суть его заключается в вычислении градиента в случайной точке гиперпространства значений функции потерь и последующем итеративном перемещении в его отрицательном направлении за счёт модификации параметров модели вплоть до достижения минимума.

При интерпретации пространственно представимых данных в геологической науке и смежных дисциплинах можно выделить два крупных класса задач: картирование структур и выявление единичных объектов. В первом случае, будь то анализ космоснимков или, например, комплексных геофизических данных, предполагается районирование территории путём выделения площадных и линейных форм, предположительно соответствующих физическим объектам и структурам определённого типа, с учётом некоторой априорной информации. Машинный алгоритм в подобных случаях служит преимущественно лишь заменой специалиста-интерпретатора, упрощая

выполнение рутинной работы. Во втором же случае задача сводится к локализации объектов конкретного типа, определённого через его эталонное модельное представление или образ аналогичного реального объекта. Речь в таком случае чаще всего идёт о крайне слабоконтрастном объекте, не выявляемом с уверенностью экспертными методами, что и становится причиной привлечения потенциально более чувствительных машинных алгоритмов. С учётом этого результаты работы такого алгоритма чаще бывают представлены не в виде контуров искомого объекта, а как вероятностная карта для всей площади поиска, характеризующая нейросетевую оценку принадлежности каждой её точки к одному из классов, охарактеризованных предложенными эталонами.

В рамках машинного распознавания образов в цифровых изображениях, безотносительно физической природы матричных данных, могут быть выделены три основных класса задач. Задачи классификации подразумевают отнесение изображения к одному из заданных классов по критерию наличия на нём образа соответствующего объекта. Детекция решает задачу определения положения (координат) предположительно присутствующего на изображении объекта по его образу. Задача же сегментации в каком-то смысле выступает объединением двух предыдущих, так как предполагает обнаружение и локализацию различных классов (семантическая сегментация) и отдельных объектов (сегментация экземпляров) в пределах одного изображения. В зависимости от специфики входных данных нейросетевые методы решения каждой из них могут предполагать существенно различные методы их предобработки, принципы формирования обучающей выборки и используемые архитектуры сетей.

Критическое рассмотрение методики и результатов предшествующих работ по данной тематике позволяет выделить ряд ключевых факторов, негативно влияющих на результаты работы ИНС в задачах распознавания образов геологических тел и структур, в особенности рудных объектов. Отчасти этому вопросу посвящена и обобщающая диссертационная работа доктора Дж. Гранека из университета Британской Колумбии [10].

Одной из основных проблем при использовании машинного обучения применительно к прогнозу минерализации являются недостаточность и плохая представительность обучающих данных: эталонные рудные объекты занимают, как пра-

вило, доли процента от общей исследуемой площади и исчисляются десятками или первыми сотнями. Для задач обучения с учителем это крайне маленькая обучающая выборка.

В аналогичных задачах распознавания образов на цифровых изображениях наиболее распространённым и положительно зарекомендовавшим себя подходом к решению проблемы недостаточной обучающей выборки является так называемая аугментация данных. Этот метод подразумевает искусственную генерацию большого числа обучающих примеров на основе нескольких качественно размеченных реальных образцов путём внесения различных искажений. В зависимости от характера данных и типа решаемой задачи это могут быть аффинные или проективные преобразования, изменение значений матрицы (например, коррекция яркости, контрастности, цветовой гаммы), внесение случайных шумов, размытия и др. С некоторыми ограничениями этот подход применим и к геонаучным данным. Так, уже в публикации В. Брауна и др. (2003) [5] отмечается, что дополнение обучающей выборки искажёнными с помощью случайного шума образами рудных объектов позволило существенно повысить точность классификации на независимом наборе тестовых данных.

Альтернативой этому может служить генерация синтетических обучающих примеров на основе цифровых моделей искомого объекта. Моделирование геологически правдоподобных, но полностью абстрактных объектов, не имеющих заранее определённых природных прототипов, может быть использовано, в частности, при экспериментальном тестировании различных нейросетевых архитектур и алгоритмов обучения как источник неограниченного количества заведомо корректно размеченных данных [10]. Однако в случае реальных объектов очевидным недостатком данного подхода, помимо трудоёмкости подготовки, является отсутствие чётких критериев адекватности модельных построений реальным геологическим обстановкам. Выбор той или иной из эквивалентных моделей, в равной степени отвечающих наличествующим объективным геологическим и геофизическим данным, полностью является сферой ответственности геолога-интерпретатора.

В значительно меньшей степени всё это касается приложений машинного обучения к картированию геологических структур. Здесь в большинстве случаев проблема недостаточности обучающей выборки стоит куда менее остро по причине

большей распространённости искомым объектов, и на передний план выходит вопрос правильности разметки данных, то есть другими словами – корректности их геологической интерпретации. При этом генерация синтетических обучающих примеров на основе достоверной и достаточно детальной геологической и петрофизической модели могла бы позволить в кратчайшие сроки добиться высокой точности распознавания, не затрачивая время и ресурсы на подготовку большого объёма реальных данных.

При этом следует заметить, что даже в случае обучения на реальных данных результаты прогноза могут существенно изменяться в зависимости от выбора априорной геологической модели объекта, на основе которой происходит формирование признаков пространства [16]. Внесение столь значительного человеческого фактора может представляться неуместным ограничением возможностей ИНС, потенциально способной выявлять ранее неизвестные структуры и паттерны в данных, а не просто автоматизировать работу конкретного эксперта.

На практике, однако, полный отказ от учёта экспертно устанавливаемых априорных критериев формирования обучающей выборки делает практически нерешаемой задачу качественной верификации получаемых результатов, а использование лишь количественных метрик сходимости модели, как будет показано ниже, не позволяет оценить полученные результаты с точки зрения их геологической осмысленности. Таким образом, теоретически предпочтительная концепция полного исключения человеческого фактора из прогнозных построений представляется на данном этапе малоперспективной из-за отсутствия возможности оперативной верификации получаемых результатов и интерпретации механизма принятого решения.

Другим часто поднимаемым вопросом, особенно если речь идёт о задачах классификации, является проблема несбалансированности обучающих меток. При обучении нейросетевого классификатора для идентификации объектов определённого типа необходимо как минимум два типа меток: положительные, отвечающие искомым объектам, и отрицательные, характеризующие вмещающую среду. При этом вмещающая среда, как правило, крайне многообразна и неоднородна, что делает выбор отрицательных меток весьма нетривиальной задачей. Отчасти решает эту проблему исполь-

зование в данном качестве (если речь идёт о поиске рудных объектов) достоверно безрудных скважин [15]. Однако такой подход существенно ограничивает применимость обсуждаемого метода, так как количество отрицательных меток должно быть как минимум сопоставимо с количеством положительных, то есть отражающих распространённость целевого класса, а в ряде случаев и превышать его, что на практике далеко не всегда выполнимо. О регионах, не обеспеченных данными бурения, речь не идёт вовсе. С другой стороны, привлечение данных бурения преследует лишь одну задачу: недопущения неверной разметки данных в случае попадания отрицательной метки на объект искомого типа. С учётом же того, что рудные объекты в общем случае занимают ничтожную долю площади территории, даже при случайном расположении отрицательных меток вероятность их попадания в ранее необнаруженную перспективную область крайне мала. Но даже если это произойдёт, единичная ошибка в разметке данных не окажет существенного влияния на результаты обучения. Предположение о допустимости случайного расположения отрицательных меток, возможно, с незначительными ограничениями по критерию пространственной близости к положительным находит подтверждение и в практических результатах отдельных исследований [7, 24].

Тем не менее сама по себе корректность разметки не решает проблему неравномерной представленности разных классов. В большинстве сред машинного обучения с учителем непредвзятость обучения достигается за счёт приблизительной равномерности выборки из каждого класса. Если это не соблюдается, задача считается несбалансированной. Редкость рудных объектов в этой ситуации выражается в крайней несбалансированности набора обучающих меток. Эта проблема ещё больше усугубляется, если ограничить задачу определённым типом минерализации, как часто бывает при прогнозе оруденения.

В задачах же детекции и сегментации, принципиально аналогичных поиску и выделению отдельных объектов на цифровой фотографии, равномерная представленность классов играет куда меньшую роль, поскольку вмещающая среда в размеченном датасете изначально интерпретируется как фоновое значение, а не альтернативный класс, равноценный искомому.

Помимо всего перечисленного, следует также обратить внимание на ошибки и неточности,

неизбежно присутствующие в самих данных. Некоторые признаки, такие как измеренные значения геофизических полей, будут иметь количественные неточности, связанные с пределами обнаружения и процедурами обработки. Другие, такие как результаты геологического картирования, в той или иной мере содержат качественные неточности, связанные с экспертной интерпретацией и систематической ошибкой выборки. Кроме того, некоторые данные могут характеризоваться существенной пространственной неоднородностью в пределах рассматриваемой площади. Так, в районах с мощным осадочным чехлом информативность как данных гамма-спектрометрии, так и карты коренных пород по объективным причинам будет существенно снижаться.

Таким образом, в отличие от многих задач машинного обучения, в которых можно доверять и данным, и их аннотации, при машинном распознавании образов в геологических данных следует учитывать, что с высокой степенью вероятности те и другие будут содержать ошибки и неточности. Ввиду этого следует уделять особое внимание отбору признаков, подготовке и предобработке данных, а также обращаться к алгоритмам, наименее подверженным влиянию одиночных выбросов, иначе сходимость при обучении может быть никогда не достигнута.

Кроме того, заслуживает упоминания проблема пусть и не специфическая для геологических данных, но оказывающая непосредственное влияние на качество распознавания. Речь идёт о широко известном феномене переобучения ИНС, который состоит в том, что при увеличении числа эпох обучения в определённый момент происходит разрыв между точностью распознавания на обучении и валидации: первая продолжает расти, в то время как вторая колеблется около некоторого предельного значения и со временем даже начинает снижаться. Это происходит по причине того, что по мере приближения к 100% точности на обучающей выборке алгоритм перестаёт выделять обобщённые признаки искомым объектам, а просто «запоминает» все входные примеры и распознаёт только их. Стандартным приёмом борьбы с переобучением служит метод исключения или «дропаута» (англ. dropout), состоящий в обнулении на каждой эпохе обучения выходов некоторого количества случайных нейронов [27]. Это приводит, по сути, к незначительному изменению архитектуры, что влияет на процесс обратного

распространения ошибки и предотвращает взаимную адаптацию нейронов к конкретным обучающим примерам. На практике также может быть полезно контролировать сходимость модели путём введения условий изменения темпа обучения в зависимости от динамики результатов на предшествующих эпохах и сохранения промежуточных значений весов для возврата к более оптимальным параметрам модели без её повторного обучения.

С учётом вышесказанного в качестве альтернативы непосредственному распознаванию образов рудных объектов при прогнозе минерализации может быть предложен «полуавтоматический» метод, представляющий на текущем этапе более реалистичным ввиду обозначенных ограничений нейросетевых методов. Он заключается в автоматизированном выделении только отдельных элементов геологического строения территории, генетически связываемых с определённым типом оруденения, а не уникального их сочетания, отвечающего локации предполагаемого рудного объекта. В этом случае выделение конкретных участков производится уже в ручном режиме путём экспертного анализа результатов распознавания с учётом априорной физико-геологической модели искомого объекта. Такой подход в значительной мере решает проблему недостаточности обучающей выборки ввиду наличия большого количества уже размеченных данных, которые могут быть использованы как непосредственно для обучения нейросетевых моделей на выделение определённых металлоторектов, так и для их предобучения на массиве геологических карт в целях повышения качества распознавания в более узко поставленных задачах.

Предлагаемый алгоритм выполнения прогнозных построений включает четыре последовательных этапа:

I. Создание прогнозной физико-геологической модели целевого объекта в составе: геологической и петрофизической моделей, а также модели физических полей.

II. Подготовка баз комплексных геологических данных (с геофизическими полями, трансформантами, геохимическими полями, спутниковыми снимками, моделями рельефа, геологическими картами и др.) для выделения элементов геологического строения и прогнозирования потенциальных рудных объектов.

III. Прогноз с использованием методов глубокого машинного обучения: создание и обучение

моделей МО; картирование геологических факторов локализации рудных объектов; выделение участков, потенциально перспективных на локализацию оруденения.

IV. Верификация результатов: оценка качества моделей на тестовых данных; интерпретация работы моделей; трёхмерное моделирование перспективных участков (при необходимости).

Ключевым в данном случае становится корректное выделение набора рудоконтролирующих факторов на начальной стадии построения модели, что требует привлечения как можно более полного набора априорных геологических, а также сопутствующих геохимических, дистанционных и других данных. Поскольку речь идёт о выделении рудных объектов заранее определённой в рамках более высокоранговой модели типологии, требуется также привлечение данных по известным аналогичным объектам за пределами рассматриваемой территории, которые при условии их локализации в сходных геологических обстановках могут быть использованы в качестве эталонов для моделирования.

С учётом вышеизложенных принципов в рамках данной работы была реализована система машинного распознавания образов по комплексным геолого-геофизическим данным, включающая свёрточные нейросетевые модели, обученные на выделение отдельных факторов локализации оруденения. В качестве рабочего инструментария использовались открытые программные продукты, широко применяемые в задачах машинного обучения. В первую очередь, фреймворк TensorFlow [25] для Python – специализированная программная библиотека для проектирования и обучения нейронных сетей с интегрированным высокоуровневым интерфейсом Keras для послойного построения моделей глубокого обучения, упрощённым механизмом внедрения предобученных моделей и повышенной производительностью на графических процессорах.

Для удобства работы с кодом использовалась среда разработки Jupiter Notebook. Работа с блокнотами Jupiter выполнялась преимущественно на локальной машине с применением среды Microsoft Visual Studio. Непосредственно обучение моделей производилось на графическом процессоре компании Nvidia с использованием программно-аппаратной архитектуры CUDA.

В качестве основного рабочего материала в рамках представленного исследования использовались ранее подготовленная база площадных гео-

физических, геохимических и геологических данных для территории Аян-Юрхской зоны в пределах Центрально-Колымского золоторудного региона (ЦКР). Более детальное описание рассматриваемой площади, первичных материалов и состав базы данных приводятся в публикации, посвящённой употреблению этих данных для выполнения формализованного прогноза на рудное золото с использованием вероятностно-статистических методов [2].

Основой для выбора целевых металлотектов и соответствующих им наборов потенциально информативных признаков служила априорная физико-геологическая модель Омчакского рудного узла как наиболее характерного золоторудного объекта данного ранга на рассматриваемой территории, ранее подготовленная в рамках работ ФГБУ «ВСЕГЕИ». Литологический контроль оруденения отражается в приуроченности рудных полей к выходам верхнепермской атканской свиты, выделяющейся зонами К и К + U специализации на картах вторичной радиохимической зональности. Связь с магматизмом выражается в локализации оруденения на периферии частично выходящих на поверхность или полностью нескрытых гранитных массивов, проявленных, в первую очередь, в виде изометричных отрицательных аномалий поля силы тяжести и его среднечастотных компонент. Зоны же крупных разрывных нарушений, исполняющие, по-видимому, роль проводящих каналов для рудного вещества, регистрируются линейными аномалиями повышенных градиентов магнитного и в меньшей степени гравитационного поля.

Импорт данных осуществлялся из файла формата .csv с сохранением в объект pandas DataFrame. Для удобства дальнейшего использования данные были пересчитаны в относительные координаты, нормализованы и преобразованы в трёхмерный массив NumPy размерами $2355 \times 2521 \times 35$, который, по сути, представляет собой многоканальное изображение, где каждый пиксель представлен трёхмерным вектором признаков. Первая пара значений соответствует линейным размерам матриц в базе, а последнее – числу слоёв, из которых два – реальные координаты точек, необходимые для корректного представления результатов распознавания, следующие четыре – слой аннотации – маски с точечными координатами или контурами объектов различных классов, закодированных определёнными значениями, а остальные – карты признаков, включаю-

щие исходные поля и различные их трансформанты.

Постановка задачи осуществлялась путём интерактивного выбора одной целевой маски и набора признаков, предположительно её характеризующих, с последующим реструктурированием массива и удалением лишних данных.

На следующем этапе при помощи скользящего окна с регулируемым шагом, то есть по степени перекрытия по каждой из осей производилось разбиение массива на тайлы (фрагменты) фиксированного размера, выбираемого в зависимости от характерных размеров целевых меток, чтобы упростить обработку и уменьшить потребление памяти при дальнейшем обучении нейронной сети. Каждый тайл представляет собой такой же трёхмерный массив, содержащий значения признаков для каждого пикселя.

Размеченный таким образом фрагментарный массив разделялся на обучающую и валидационную выборки с отсеиванием тайлов, не содержащих объекты целевого класса, а также приводился к формату, необходимому для обучения нейросетевых моделей. Для искусственного увеличения имеющейся недостаточной выборки и повышения робастности модели обучающий датасет увеличивался в 10 раз простым копированием, после чего к нему применялся комплекс процедур аугментации. Последние включали случайные повороты, отражения, ограниченное масштабирование и внесение гауссова шума. Для оценки качества подготовленной выборки и проверки корректности применения методов аугментации данных выполнялась визуализация ограниченного числа случайных примеров.

Полученные таким образом обучающий и валидационный наборы данных тензорного формата, стандартного для обучения нейронных сетей в TensorFlow, перемешивались, разбивались для обеспечения более стабильной сходимости модели на мини-пакеты по четыре элемента и подавались на вход нейросети.

По результатам тестирования нескольких различных моделей предпочтение было отдано нейронной сети с относительно простой свёрточной архитектурой типа U-Net [21], хорошо зарекомендовавшей себя в задачах сегментации слабokon-трастных изображений. Схема использованной U-Net-подобной архитектуры приведена на рис. 1.

Функция `input_layer` определяет входной слой нейронной сети с заданными размерами входного изображения и количеством каналов.

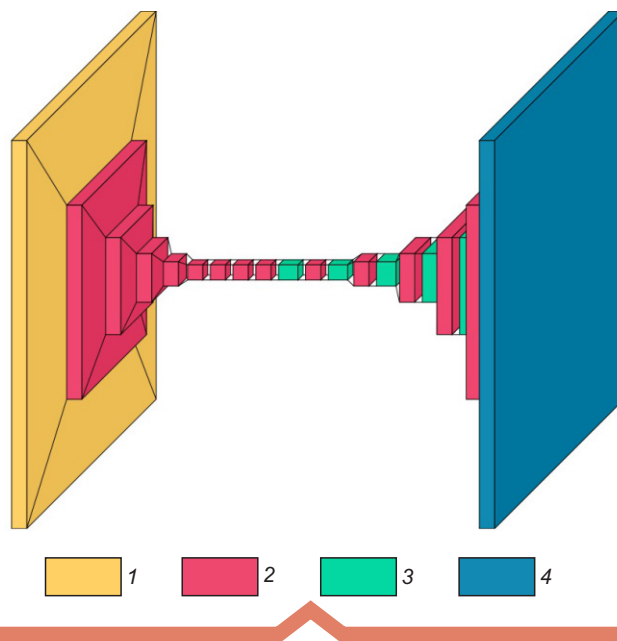


Рис. 1. Визуализация архитектуры нейронной сети типа U-Net:

1 – InputLayer; 2 – Sequential; 3 – Concatenate; 4 – Conv2DTranspose

Энкодер в представленной архитектуре состоит из семи последовательных свёрточных блоков, позволяющих извлекать признаки на разных уровнях абстракции. Каждый блок включает свёрточный слой с заданным числом фильтров (16, 32, 64, 128, 128, 128, 128) и размером ядра 4, опциональный слой пакетной нормализации, ускоряющий обучение и улучшающий обобщающую способность модели, и функцию активации LeakyReLU. Первый блок не использует пакетную нормализацию, что может быть полезно при небольших объёмах данных, как в нашем случае, или при ограниченных вычислительных ресурсах, чтобы уменьшить количество обучаемых параметров. Количество фильтров в первых четырёх блоках удваивается с каждым последующим, начиная с 16-го. Это соответствует общей концепции архитектуры U-Net, которая имеет сквозную связь между энкодером и декодером и использует полносвязные карты признаков для объединения низкоуровневой и высокоуровневой информации. В последующих трёх слоях число фильтров не повышается, так как это при небольшом объёме входных данных может легко привести к снижению эффективности модели, поскольку в этих слоях уже содержится много информации об изображении.

и дальнейшее увеличение числа фильтров не приведёт к значительному улучшению результатов, а в случае переобучения ухудшит их. Экспериментально подобранное под конкретную задачу оптимальное число фильтров позволяет модели изучать более сложные функции при сохранении относительно небольшого количества параметров и вычислительной эффективности.

Блок декодера состоит из транспонированного свёрточного слоя, увеличивающего размерность выходных данных, слоя пакетной нормализации, опционального слоя Dropout, отключающего выходы 20% случайных нейронов, и функции активации ReLU. Пакет слоёв декодера зеркально по-

вторяет энкодер по числу слоёв и фильтров, позволяя получить на выходе сегментированную матрицу, восстановленную до исходного размера входного патча. При этом в декодере также используются блоки, которые объединяют высокоуровневые и низкоуровневые признаки для получения более точных и детализированных результатов сегментации. Для передачи низкоуровневой информации в глубокие слои декодера создаются дополнительные связи между блоками, так называемыми skip connections.

Функция `output_layer` создаёт выходной слой, используемый для получения сегментированного изображения с установленной принадлежностью




Рис. 2. Распознавание интрузивных массивов по комплексным геофизическим данным:

1 – обучающая выборка; 2 – целевой признак; 3 – отсутствие признака; интрузивные массивы: 4 – выходящие на дневную поверхность, 5 – не вскрытые эрозией, выделенные по геофизическим данным

каждого пикселя к определённому классу. При этом используется сигмоидальная активационная функция, преобразующая значения выходов нейронов в матрицу вероятностей. Количество каналов выходного слоя соответствует количеству классов, на которые разбивается изображение в задаче сегментации.

В качестве функции потерь использована взвешенная комбинация BinaryCrossentropy и Dice Loss. Такой выбор обусловлен тем, что Dice Loss учитывает пространственную структуру и относительный размер объектов, но может быть менее чувствительна к границам объектов, особенно если они нечёткие, в то время как BinaryCrossentropy хорошо работает именно для определения границ объектов сегментации.

Поскольку речь идёт о несбалансированной задаче с относительно малой представленностью целевого класса, при обучении модели использовался взвешенный коэффициент Dice, учитывающий

не только точность и полноту предсказаний модели, но и разные вклады каждого класса в общую метрику.

Оптимизация параметров нейронной сети выполнялась с использованием алгоритма Adam, реализующего концепцию стохастического градиентного спуска с адаптивной оценкой моментов градиентов первого и второго порядков.

По результатам нескольких циклов обучения модели распознавания интрузивных массивов на 30-й эпохе с набором признаков, включающим составляющую поля силы тяжести от слоя 4–5 км, его горизонтальный градиент и модуль полного градиента аномального магнитного поля, достигнута сходимость на уровне Dice = 77,8 на валидации (рис. 2).

Аналогичные результаты получены для модели, обученной на выделение выходов Атканской свиты (рис. 3) по набору данных, включавшему надфоновые компоненты радиогеохимического




Рис. 3. Распознавание выходов пород Атканской свиты по АГС-данным:

1 – целевой признак; 2 – отсутствие признака; 3 – границы выходов Атканской свиты; 4 – обучающая выборка

поля и карту районирования гравитационного и магнитного полей. Оптимальный результат без переобучения модели достигнут на 40-й эпохе со значением метрики Dice = 79,2 на валидации.

В задаче распознавания разрывных нарушений (рис. 4), наиболее сложной из рассмотренных ввиду неоднородной проявленности разломов различного ранга в геофизических полях, использовалась функция потерь Binary Focal Crossentropy с весовым коэффициентом $\alpha = 0,9$ и стандартным значением параметра фокусировки $\gamma = 2$. Наилучший результат со значением метрики IoU = 73,3 получен на 55-й эпохе с набором признаков, включавшим асимметрию аномального магнитного поля, его параметр tilt

и горизонтальный градиент локальной компоненты поля силы тяжести.

Применение полученных моделей к тестовым данным и сопоставление результатов с реально закартированными и выделенными по геофизическим данным контурами целевых объектов демонстрирует общее совпадение положения фактических и прогнозируемых крупных тел и структур, с частными расхождениями в геометрии и мелких деталях. Последнее может быть связано как с неоднородностью вещественного состава и, следовательно, проявленности в полях отдельных массивов и литологических разностей, так и с недостатками использованной разметки, не всегда корректно отражающей реальную форму тел.




Рис. 4. Распознавание разрывных нарушений по комплексным геофизическим данным:

1 – обучающая выборка; 2 – целевой признак; 3 – отсутствие признака; разрывные нарушения: 4 – главные, 5 – второстепенные

Сводная карта (рис. 5), полученная путём наложения сегментированных бинарных слоёв с выделенными геологическими факторами контроля оруденения, позволяет визуально оценить связь между прогнозируемыми металлотектами и реальным распространением минерализации целевого типа. Известные крупнообъёмные золоторудные объекты, в том числе Омчакский рудный узел, послуживший основой для создания использованной априорной ФГМ, вполне отвечают ожидаемому критерию локализации, выражающемуся в пространственном совпадении предполагаемых выходов рудовмещающих толщ, зон крупных разрывных нарушений и периферии припо-

верхностных интрузивных массивов на удалении 4–10 км.

При этом нужно отметить, что по формальному критерию качества обучения моделей – метрикам Dice – полученные результаты являются достаточно слабыми для задач сегментации. Однако следует учитывать, что метрика Dice основывается на сравнении площадей целевых объектов и множеств пикселей, отнесённых к целевому классу по результатам распознавания, не учитывая другие аспекты сегментации, такие как форма и расположение объектов на изображении. А разметка как тренировочного, так и валидационного датасета – также результат отчасти субъективной

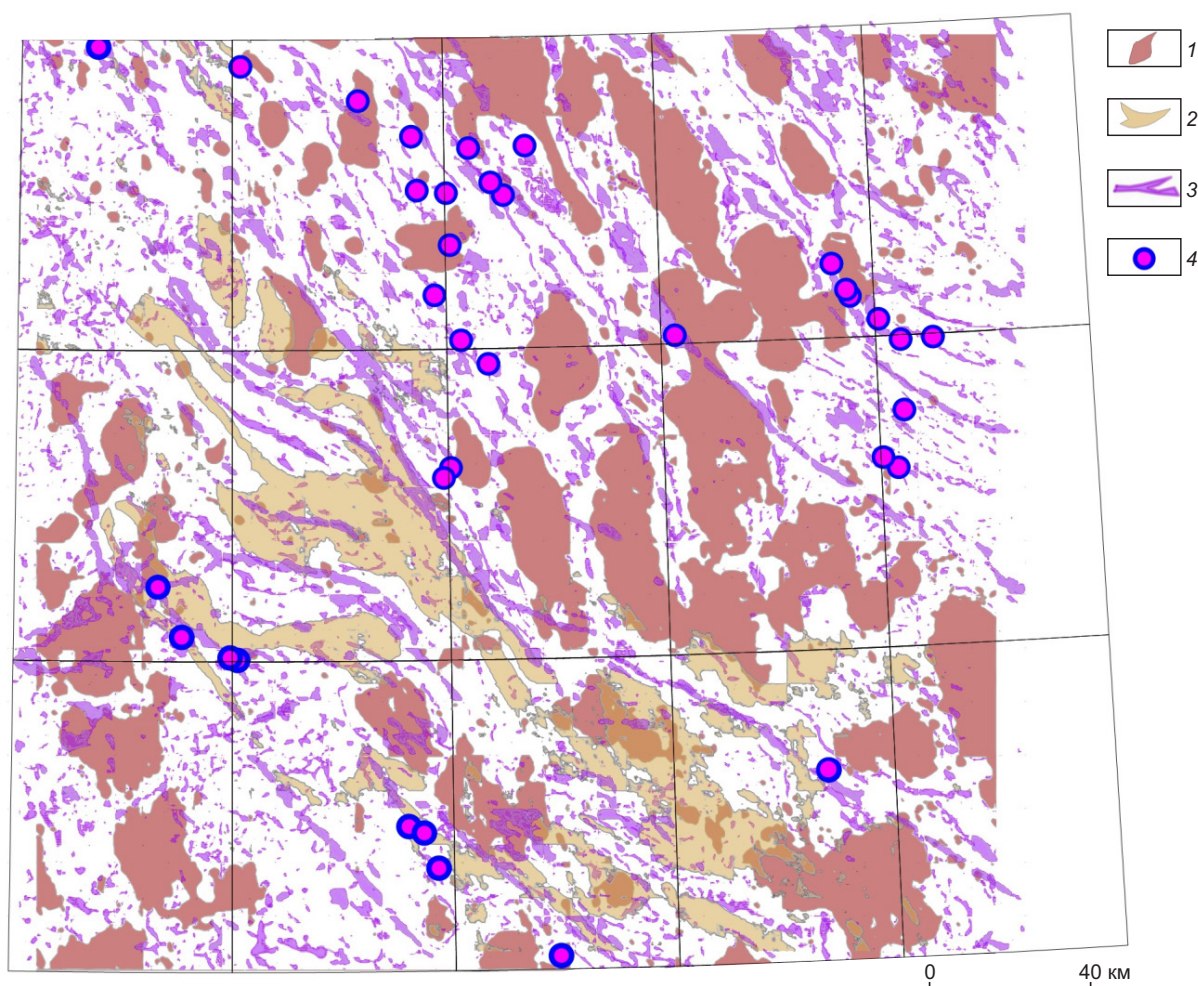


Рис. 5. Сводная карта распознанных факторов локализации крупнообъёмного золотого оруденения, выделенных на основе априорной ФГМ Омчакского рудного узла:

1 – интрузивные массивы; 2 – границы выходов Атканской свиты; 3 – предполагаемые разрывные нарушения; 4 – золоторудные месторождения

интерпретации составителей геологических карт, с которых были сняты контуры целевых объектов. Таким образом, возникновение ошибок второго рода, понижающих коэффициенты Dice и IoU, может быть следствием выделения реальных объектов, не отмеченных в валидационных данных, например не выходящих на поверхность интрузивных массивов.

Поэтому при оценке качества моделей для задач сегментации геолого-геофизических данных необходимо учитывать не только количественные метрики качества, но и другие аспекты, такие как форма и расположение объектов на изображении, а также оценку полезности выделенных объектов для конечной цели задачи. Кроме того, желательно при возможности проводить валидацию модели на нескольких независимых наборах данных и анализировать её результаты в экспертном режиме, чтобы убедиться в корректности выделения целевых объектов, отсутствии явных противоречий картам использованных признаков и общем соответствии полученных результатов априорным представлениям о геологическом строении региона.

Подготовленные нейросетевые модели достаточно универсальны, так как обучены на распознавание не уникальных меток, характерных только для определённой территории, а на выделение повсеместно распространённых типов геологических объектов и структур, образы которых в геолого-геофизических данных от региона к региону отличаются лишь в отдельных аспектах. Это позволяет предполагать возможность переноса результатов обучения на другие площади, при условии их покрытия аналогичного качества съёмками, с дообучением лишь на небольшом объёме новых данных, нужных для внесения корректи-

ровок в веса моделей. Данная задача является частным случаем так называемой доменной адаптации, к реализации которой на сегодняшний день разработан целый ряд результативных подходов.

Таким образом, применение машинного распознавания образов для решения задач прогноза с точки зрения верифицируемости и практической применимости на данном этапе представляется наиболее перспективным в рамках комплексного подхода к интерпретации геолого-геофизических данных на основе физико-геологического моделирования. Нейросетевые модели здесь играют роль инструмента автоматического выделения заранее определённых типов металлотектов, а потенциально перспективные участки выделяются в экспертном режиме с учётом предполагаемого комплекса факторов локализации целевых рудных объектов. Кроме того, такой подход позволяет в значительной мере уйти от проблемы недостаточности обучающих примеров, как в случае с поиском единичных объектов, и не полагаться полностью на методы аугментации или другие подходы к искусственному увеличению выборки, требующие дополнительного обоснования применимости.

Однако необходимо учитывать, что качественная предобработка данных и осмысленный выбор признаков, независимо от постановки задачи и выбранного алгоритма машинного обучения, играют первостепенную роль. Эффективность работы любой модели может быть сведена к нулю обучением на существенно неоднородных, избыточных или напрямую не связанных с целевыми объектами признаках, а различные по комплексу параметров нейросетевые решения, напротив, могут дать близкие результаты при условии использования качественных и релевантных входных данных.

СПИСОК ЛИТЕРАТУРЫ

1. Карамышев А. В. Нейросетевые методы распознавания образов в задачах картирования геологических структур и оценки минерального потенциала // Геология, геоэкология и ресурсный потенциал Урала и сопредельных территорий. – 2022. – № 10. – С. 189–193.
2. Карамышев А. В., Фёдорова К. С., Тарасов А. В. Прогноз скрытого золотого оруденения в пределах Центрально-Колымского района по комплексу геолого-геофизических признаков методом распознавания // Руды и металлы. – 2020. – № 2. – С. 10–24.
3. Barnett C., Williams P. Using Geochemistry and Neural Networks to Map Geology under Glacial Cover // GBC Technical report 2009-03. – 2009. – P. 1–26.
4. Bonham-Carter G. F., Agterberg F. P., Wright D. F. Integration of geological datasets for gold exploration in Nova Scotia // Digital Geologic and Geographic Information Systems. – 1989. – № 10. – P. 15–23.
5. Brown W. M., Gedeon T. D., Groves D. I. Use of Noise to Augment Training Data: A Neural Network Method of Mineral-Potential Mapping in Regions of Limited

- Known Deposit Examples // Natural Resources Research. – 2003. – 12. – P. 141–152.
6. *Brown W. M., Gedeon T. D., Groves D. I., Barnes R. G.* Artificial neural networks: A new method for mineral prospectivity mapping // Australian Journal of Earth Sciences. – 2000. – 47:4. – P. 757–770.
 7. *Carranza E. J. M., Laborte A. G.* Data-driven predictive mapping of gold prospectivity, Baguio district, Philippines: application of Random Forests algorithm // Ore Geol. Rev. – 2015. – 71. – P. 777–787.
 8. *Cedou M., Gloaguen E., Blouin M., Caté A., Paiement J. P., Tirdad S.* Preliminary geological mapping with convolution neural network using statistical data augmentation on a 3D model // Computers & Geosciences. – 2022. – № 167(6). – P. 105187.
 9. *Dramsch J. S.* 70 years of machine learning in geoscience in review // Advances in geophysics. – 2020. – № 61. – P. 1–55.
 10. *Granek J.* Application of machine learning algorithms to mineral prospectivity mapping // PhD diss. – University of British Columbia, 2016.
 11. *Harris D., Pan G.* Mineral Favorability Mapping: A Comparison of Artificial Neural Networks, Logistic Regression, and Discriminant Analysis // Natural Resources Research. – 1999. – № 8. – P. 93–109.
 12. *Harris D., Zurcher L., Stanley M.* [et al.] A Comparative Analysis of Favorability Mappings by Weights of Evidence, Probabilistic Neural Networks, Discriminant Analysis, and Logistic Regression // Natural Resources Research. – 2003. – № 12. – P. 241–255.
 13. *Krizhevsky A., Sutskever I., Hinton G. E.* ImageNet Classification with Deep Convolutional Neural Networks // Advances in Neural Information Processing Systems 25, Curran Associates, Inc. – 2012. – P. 1097–1105.
 14. *LeCun Y., Boser B., Denker J. S., Henderson D., Howard R. E., Hubbard W., Jackel L. D.* Backpropagation Applied to Handwritten Zip Code Recognition // Neural Computation. – 1989. – № 1 (4). – P. 541–551.
 15. *Li S., Chen J., Xiang J.* Applications of deep convolutional neural networks in prospecting prediction based on two-dimensional geological big data // Neural Comput & Applic. – 2019. – № 32. – P. 2037–2053.
 16. *Lindsay M. D., Piechocka A. M., Jessell M. W., Scalzo R., Giraud J., Pirot G., Cripps E.* Assessing the impact of conceptual mineral systems uncertainty on prospectivity predictions // Geosci. Front. – 2022. – № 13. – P. 101435.
 17. *Maas A. L., Hannun A. Y., Ng A. Y.* Rectifier nonlinearities improve neural network acoustic models // Proc. Icml. – 2013. – V. 30, № 1. – P. 3.
 18. *McCulloch W. S., Pitts W. A.* Logical calculus of the ideas immanent in nervous activity // Bulletin of Mathematical Biophysics. – 1943. – № 5. – P. 115–133.
 19. *McMillan M., Fohring J., Haber E., Granek J.* Orogenic gold prospectivity mapping using machine learning // ASEG Extended Abstracts. – 2019. – № 1. – P. 1–4.
 20. *Porwal A., Carranza E. J. M., Hale M.* Artificial Neural Networks for Mineral-Potential Mapping: A Case Study from Aravalli Province, Western India // Natural Resources Research. – 2003. – № 12. – P. 155–171.
 21. *Ronneberger O, Fischer P, Brox T.* U-net: Convolutional networks for biomedical image segmentation // International Conference on Medical image computing and computer-assisted intervention. – 2015. – P. 234–241.
 22. *Rosenblatt F.* Principles of Neurodynamics; Perceptrons and the Theory of Brain Mechanisms // Washington : Spartan Books, 1962. – 616 p.
 23. *Rosenblatt F.* The Perceptron – A Perceiving and Recognizing Automaton // Technical Report 85-460-1, Cornell Aeronautical Laboratory. – 1957.
 24. *Singer D. A., Kouda R.* Use of a neural network to integrate geoscience information in the classification of mineral deposits and occurrences // Proceedings of Exploration 97: Fourth Decennial International Conference on Mineral Exploration: Toronto, 1997. – P. 127–134.
 25. *Singh P., Manure A.* Learn TensorFlow 2.0 : Implement Machine Learning and Deep Learning Models with Python. – 2020. – 164 p.
 26. *Sun T., Chen F., Zhong L., Liu W., Wang Y.* GIS-based mineral prospectivity mapping using machine learning methods: A case study from Tongling ore district, eastern China // Ore Geology Reviews. – 2019. – 109. – P. 26–49.
 27. *Wan L., Zeiler M., Zhang S., Le Cun Y, Fergus R.* Regularization of neural networks using dropconnect // International conference on machine learning. – 2013. – P. 1058–1066.

REFERENCES

1. *Karamyshev A. V.* Neyrosetevyye metody raspoznavaniya obrazov v zadachakh kartirovaniya geologicheskikh struktur i otsenki mineral'nogo potentsiala [Neural network methods for pattern recognition in problems of mapping geological structures and assessing mineral potential], Geologiya, geoekologiya i resursnyy potentsial Urala i sopredel'nykh territoriy, 2022, No. 10, pp. 189–193. (In Russ.)
2. *Karamyshev A. V., Fodorova K. S., Tarasov A. V.* Prognoz skrytogo zolotogo orudneniya v predelakh Tsentral'no-Kolymskogo rayona po kompleksu geologo-

- geofizicheskikh priznakov metodom raspoznavaniya [Forecast of hidden gold mineralization within the Central Kolyma region based on a complex of geological and geophysical features by the recognition method], Rudy i metally [Ores and Metals], 2020, No. 2, pp. 10–24. (In Russ.)
3. Barnett C., Williams P. Using Geochemistry and Neural Networks to Map Geology under Glacial Cover, GBC Technical report 2009-03, 2009, pp. 1–26.
 4. Bonham-Carter G. F., Agterberg F. P., Wright D. F. Integration of geological datasets for gold exploration in Nova Scotia, Digital Geologic and Geographic Information Systems, 1989, No. 10, pp. 15–23.
 5. Brown W. M., Gedeon T. D., Groves D. I. Use of Noise to Augment Training Data: A Neural Network Method of Mineral–Potential Mapping in Regions of Limited Known Deposit Examples, Natural Resources Research, 2003, 12, pp. 141–152.
 6. Brown W. M., Gedeon T. D., Groves D. I., Barnes R. G. Artificial neural networks: A new method for mineral prospectivity mapping, Australian Journal of Earth Sciences, 2000, 47:4, pp. 757–770.
 7. Carranza E. J. M., Laborte A. G. Data-driven predictive mapping of gold prospectivity, Baguio district, Philippines: application of Random Forests algorithm, Ore Geol. Rev, 2015, 71, pp. 777–787.
 8. Cedou M., Gloaguen E., Blouin M., Caté A., Païement J. P., Tirdad S. Preliminary geological mapping with convolution neural network using statistical data augmentation on a 3D model, Computers & Geosciences, 2022, No. 167(6), pp. 105187.
 9. Dramsch J. S. 70 years of machine learning in geoscience in review, Advances in geophysics, 2020, No. 61, pp. 1–55.
 10. Granek J. Application of machine learning algorithms to mineral prospectivity mapping, PhD diss, University of British Columbia, 2016.
 11. Harris D., Pan G. Mineral Favorability Mapping: A Comparison of Artificial Neural Networks, Logistic Regression, and Discriminant Analysis, Natural Resources Research, 1999, No. 8, pp. 93–109.
 12. Harris D., Zurcher L., Stanley M. [et al.] A Comparative Analysis of Favorability Mappings by Weights of Evidence, Probabilistic Neural Networks, Discriminant Analysis, and Logistic Regression, Natural Resources Research, 2003, No. 12, pp. 241–255.
 13. Krizhevsky A., Sutskever I., Hinton G. E. ImageNet Classification with Deep Convolutional Neural Networks, Advances in Neural Information Processing Systems 25, Curran Associates, Inc, 2012, pp. 1097–1105.
 14. LeCun Y., Boser B., Denker J. S., Henderson D., Howard R. E., Hubbard W., Jackel L. D. Backpropagation Applied to Handwritten Zip Code Recognition, Neural Computation, 1989, No. 1 (4), pp. 541–551.
 15. Li S., Chen J., Xiang J. Applications of deep convolutional neural networks in prospecting prediction based on two-dimensional geological big data, Neural Comput & Applic, 2019, No. 32, pp. 2037–2053.
 16. Lindsay M. D., Piechocka A. M., Jessell M. W., Scalzo R., Giraud J., Piroit G., Cripps E. Assessing the impact of conceptual mineral systems uncertainty on prospectivity predictions, Geosci. Front, 2022, No. 13, pp. 101435.
 17. Maas A. L., Hannun A. Y., Ng A. Y. Rectifier nonlinearities improve neural network acoustic models, Proc. Icml, 2013, V. 30, No. 1, pp. 3.
 18. McCulloch W. S., Pitts W. A. Logical calculus of the ideas immanent in nervous activity, Bulletin of Mathematical Biophysics, 1943, No. 5, pp. 115–133.
 19. McMillan M., Fohring J., Haber E., Granek J. Orogenic gold prospectivity mapping using machine learning, ASEG Extended Abstracts, 2019, No. 1, pp. 1–4.
 20. Porwal A., Carranza E. J. M., Hale M. Artificial Neural Networks for Mineral-Potential Mapping: A Case Study from Aravalli Province, Western India, Natural Resources Research, 2003, No. 12, pp. 155–171.
 21. Ronneberger O., Fischer P., Brox T. U-net: Convolutional networks for biomedical image segmentation, International Conference on Medical image computing and computer-assisted intervention, 2015, pp. 234–241.
 22. Rosenblatt F. Principles of Neurodynamics; Perceptrons and the Theory of Brain Mechanisms, Washington, Spartan Books, 1962, 616 p.
 23. Rosenblatt F. The Perceptron – A Perceiving and Recognizing Automaton, Technical Report 85-460-1, Cornell Aeronautical Laboratory, 1957.
 24. Singer D. A., Kouda R. Use of a neural network to integrate geoscience information in the classification of mineral deposits and occurrences, Proceedings of Exploration 97: Fourth Decennial International Conference on Mineral Exploration: Toronto, 1997, pp. 127–134.
 25. Singh P., Manure A. Learn TensorFlow 2.0 : Implement Machine Learning and Deep Learning Models with Python, 2020, 164 p.
 26. Sun T., Chen F., Zhong L., Liu W., Wang Y. GIS-based mineral prospectivity mapping using machine learning methods: A case study from Tongling ore district, eastern China, Ore Geology Reviews, 2019, 109, pp. 26–49.
 27. Wan L., Zeiler M., Zhang S., Le Cun Y., Fergus R. Regularization of neural networks using dropconnect, International conference on machine learning, 2013, pp. 1058–1066.

Статья поступила в редакцию 13.06.24; одобрена после рецензирования 03.07.24; принята к публикации 03.07.24.
The article was submitted 13.06.24; approved after reviewing 03.07.24; accepted for publication 03.07.24.