

УДК 004.891.3; 550.8.053

И.И. Никулин¹, А.А. Самсонов², М.В. Кузнецов³**КОЛЬЦЕВЫЕ СТРУКТУРЫ НОРИЛЬСКОГО МЕТАЛЛОГЕНИЧЕСКОГО РАЙОНА В НЕЙРОСЕТЕВОМ КЛАСТЕРНОМ АНАЛИЗЕ ПЛОЩАДНЫХ ГЕОФИЗИЧЕСКИХ ДАННЫХ**

ООО «Норильскгеология», 195220, Санкт-Петербург, Гражданский проспект, 11
ФГБОУ ВО «Московский государственный университет имени М.В. Ломоносова»,
119991, Москва, ГСП-1, Ленинские Горы, 1

LLC «Norilskgeologia», 195220, Saint Petersburg, Grajdansky ave., 11
Lomonosov Moscow State University, 119991, Moscow, GSP-1, Leninskiye Gory, 1

По разработанной авторами методике автоматической экспресс-интерпретации площадных геофизических данных построена комплексная геофизико-математическая модель Норильского металлогенического района, состоящая из пятнадцати уровней иерархии. Создание модели базируется на использовании математического аппарата нечеткой логики — искусственных нейронных сетей без учителя по методу самоорганизующихся карт Кохонена. Обосновано формирование групп кластеров, характеризующих возможные связи между многомерными геофизическими данными, и проанализировано наличие взаимосвязей между ними путем выявления корреляционных зависимостей. Проанализированы различные геофизические трансформанты с применением самоорганизующихся карт Кохонена. Определен ряд входных показателей-репрезентантов своих групп, на основе которых построена геофизико-математическая модель в виде двумерной карты кластеров с использованием инструментария нечеткой логики. Сформированы терминологические множества для каждой группы кластеров, задан вид функций принадлежности ранее неизвестных геологических объектов по новым проинтерпретированным данным.

Вычисленные кластеры по результатам исследования отражают северо-западный фрагмент полей базальтового магматизма трапповой формации, в пределах которого выделены две кольцевые структуры. В западной части участка исследований модельная кольцевая структура отражает Болгохтохский шток гранодиоритов. Вторая кольцевая структура — Пясинская, ранее неизвестная, указывает на наличие на большой глубине куполовидного объекта — возможного очага корневых зон интрузий норильского комплекса. Экспериментальное исследование подтвердило адекватность построенной модели и эффективность ее использования с целью экспрессного анализа геофизических данных и принятия решений для геолого-поисковых задач.

Ключевые слова: кольцевые структуры, площадная геофизика, иерархическая модель, искусственная нейронная сеть, карта Кохонена, нечеткая логика, кластерный анализ, Норильский район.

An integrated geophysical and mathematical model of the Norilsk metallogenic region has been built according to the authors' method of automatic express interpretation of areal geophysical data. It consists of fifteen levels of hierarchy. The model is based on the use of the mathematical apparatus of fuzzy logic — artificial neural networks without a teacher using the method of self-organizing Kohonen maps. Formation of cluster groups is justified. Clusters characterize to the greatest extent possible connections between multidimensional geophysical data. The presence of relationships between them is analyzed by identifying correlation dependences. Analysis of various geophysical transformants using self-organizing Kohonen maps is carried out. A number of input indicators-representatives of their groups are determined, on the basis of which a geophysical-mathematical model is built. A model in the form of a two-dimensional map of clusters using fuzzy logic tools. Terminological sets were formed for each group of clusters. The form of membership functions of previously unknown geological objects is given according to new interpreted data. The calculated clusters according to the results of the study reflect the northwestern fragment of the basaltic magmatism fields of the trap formation, within which two ring structures have been distinguished. In the western part of the study area, the model ring structure reflects the Bolgokhtokhsy stock of granodiorites. The second, the Pyasinskaya ring structure, previously unknown, indicates the presence of a dome-shaped object at a great depth — a possible source of root zones of intrusions of the Norilsk complex. The conducted experimental study confirmed the adequacy of the constructed model and the effectiveness of

¹ ООО «Норильскгеология», заместитель директора по развитию геологоразведочных работ; *e-mail*: nikulinII@nornik.ru

² Московский государственный университет имени М.В. Ломоносова, геологический факультет, вед. инженер; *e-mail*: samsonov@geol.msu.ru

³ Московский государственный университет имени М.В. Ломоносова, геологический факультет, магистрант; *e-mail*: kuznetsov.maxi@yandex.ru

its use for the purpose of express analysis of geophysical data and decision-making in geological prospecting tasks.

Key words: ring structures, areal geophysics, hierarchical model, artificial neural network, Kohonen map, fuzzy logic, cluster analysis, Norilsk district.

Введение. В результате многолетних специализированных исследований в рамках поисковых, геологоразведочных и тематических работ многие авторы выделяли различные структурные зоны, отвечающие главным камерам и подводящим каналам магматических образований норильского типа трапповой формации. Достоверно известны направления безжерловых излияний базальтов без установления их эпицентров [Геология ..., 2020].

Сделана попытка интерпретировать большой объем геофизических данных, собранных за разные годы, с целью выявления ореолов наиболее вероятных эпицентров магматизма. Все данные характеризуются разными масштабом и набором, поэтому был необходим универсальный подход к их сведению для дальнейшей обработки и получения адекватных результатов.

Существует множество способов автоматической обработки большого количества данных. Но универсальный метод обработки данных геофизических площадных работ до сих пор не разработан. Комплексный анализ и комплексная интерпретация геофизических полей наряду с непосредственным комплексированием геофизических методов представляют наиболее эффективное средство повышения однозначности решения обратных задач геофизики. Если комплексный анализ по набору предварительно рассчитанных атрибутов полей обеспечивает решение задач структурно-тектонического районирования изучаемых площадей, то комплексная интерпретация геополей ориентирована на количественную оценку геометрических параметров (глубина, форма и элементы залегания) и физических (физические свойства) искомых объектов (источники, образующие аномалии). Решение задач комплексного анализа реализуется как при наличии эталонных объектов, так и при их отсутствии.

Отсутствие эталонных объектов, на которых проводится оценка статистических характеристик и информативности изучаемых признаков, приводит к необходимости разработать алгоритмы обработки данных комплекса на принципах самообучения. Распознавание образов без обучения на эталонных объектах называется самообучением. Самообучение — эффективный инструмент, когда связи между данными неочевидны или кажутся отсутствующими, потому что их слишком много [Hu et al., 2019; Rodrigo, Cavalcanti de, 2019]. При этом число классов и статистические характеристики (распределение) признаков по каждому классу должны быть получены в процессе обработки исходных данных. При распознавании образов без обучения термин «классификация»

больше отвечает сути задачи, поскольку в итоге площадь исследования разделяется на конкретное число однородных по комплексу признаков классов.

Представляется, что можно использовать нейронные сети, которые без значимых финансовых и временных затрат позволяли бы в экспресс-режиме обрабатывать огромное количество данных, тем самым направляя внимание даже самого неопытного интерпретатора на нюансы исследуемого материала. В научном мире подобные исследования называются Data-mining — поиск скрытой информации в околобесконечном количестве сырых (необработанных) данных любой размерности (1D, 2D, 3D, 4D и т.д.), а методы их реализации становятся все более экспрессными [Larose, 2014; Samanta et al., 2018].

Среди алгоритмов классификации выделяются: эвристические, использующие различные приемы суммирования (или произведения) признаков; корреляционные, базирующиеся на аппарате компонентного и факторного анализа; статистические, основанные на проверке статистических гипотез.

Самоорганизующиеся карты Кохонена (self organizing maps, SOM) — одна из разновидностей нейросетевых алгоритмов [Кохонен, 2008]. Основное отличие этой технологии от иных нейросетей, обучаемых по алгоритму обратного распространения, заключается в том, что используется метод самообучения без учителя, т. е. результат обучения зависит только от структуры входных данных [Silva et al., 2017]. Нейронные сети этого типа часто применяют для решения разнообразных задач — от восстановления пропусков в данных до анализа данных и поиска закономерностей, например, в финансовой задаче [Hu et al., 2019], в горно-обогатительном процессе [Кириллов и др., 2013], при обработке тысяч анализов сплошного геохимического опробования керна при технологической типизации руд [Никулин, Савко, 2015; Kalashnikov et al., 2020], а также используется их особенность в устойчивости самоорганизующихся карт Кохонена (СОК) к зашумленным данным, быстрому и неуправляемому самообучению и возможности упрощения многомерных входных данных с помощью визуализации. Нами с помощью метода СОК обработаны данные площадных геофизических работ в масштабе 1:50 000 (гравиметрическая и магнитометрическая съемки). Объем данных очень велик, и между ними преимущественно нечеткие связи. Переинтерпретация многомерных данных в двумерные диаграммы нечетких связей дает большую фору при принятии дальнейших решений

по исследуемым объектам [Rodrigo, Cavalcanti de, 2019; Todeva et al., 2019].

Нейросеть состоит всего из двух слоев — входного (распределительного) и выходного, который также называется слоем Кохонена. В нейросети Кохонена каждый нейрон входного слоя связан со всеми нейронами выходного, а внутри слоев связей нет. На нейроны входного слоя подаются векторы признаков кластеризуемых объектов. Число выходных нейронов сети Кохонена равно числу кластеров, которое должно быть построено моделью, и каждый нейрон ассоциирован с определенным кластером. Выходы обрабатываются по принципу «победитель забирает все», т.е. нейрон с наибольшим значением выхода выбирает единицу, а выходы остальных обнуляются.

В результате работы нейросети формируется самоорганизующаяся карта Кохонена, консолидирующая многомерные данные с нечеткими зависимостями в двумерное изображение. Обычно используются одно- и двумерные сетки. При этом каждый нейрон представляет собой n -мерный вектор-столбец $w=[w_1, w_2, \dots, w_n]^T$, где n определяется размерностью исходного пространства (размерностью входных векторов), T — символ транспонирования. СОК подразумевает использование упорядоченной структуры нейронов. Применение одно- и двумерных сеток связано с тем, что возникают проблемы при отображении пространственных структур большей размерности (при этом опять возникают проблемы с понижением размерности до двумерной, представимой на мониторе).

Обычно нейроны расположены в узлах двумерной сетки с прямоугольными или шестиугольными ячейками. При этом нейроны также взаимодействуют между собой. Величина этого взаимодействия определяется расстоянием между нейронами на карте. А число нейронов в сетке определяет степень детализации результата работы алгоритма, и в конечном счете от этого зависит точность обобщающей способности карты. При этом легко заметить, что для шестиугольной сетки расстояние между нейронами больше совпадает с евклидовым расстоянием, чем для четырехугольной сетки.

В итоге геолого-геофизические исследования вооружаются единообразной методикой расчета, без привязки к какой-либо функциональной модели типа связи. Автоматизация выделения уникальных объектов в информационных геофизических полях может оказаться эффективным подспорьем при региональном прогнозе.

Материалы и методы исследований. В пределах Норильского металлогенического района нами собраны данные геофизических площадных работ масштаба 1:50 000, содержащие (в скобках — условные сокращения):

— гравиметрическую вертикальную производную (VD_grav),

— гравиметрический горизонтальный градиент (HG_grav),

— исходное гравитационное поле (GRAV),

— угол наклона гравитационного вектора (Tilt_grav),

— магнитометрическую вертикальную производную (VD_mag),

— аналитический сигнал магнитного поля (квадратный корень из суммы квадратов производных в направлениях x , y и z) (AS_mag),

— магнитометрический горизонтальный градиент (HG_mag),

— угол наклона магнитного вектора (Tilt_mag),

— общий вектор магнитной индукции (ТМІ).

Общий сценарий состоит из нескольких основных блоков-алгоритмов (рис. 1): 1) сбор и объединение данных, 2) заполнение пропусков, 3) редактирование выбросов, 4) сглаживание, 5) самоорганизующиеся сети, 6) СОК, 7) основная карта, 8) ГИС-проект. Каждый блок-алгоритм — набор математических формул, решающих определенную функцию, обозначенную в его названии. Данные собираются из файлов, полученных в результате геофизических съемок, и подвергаются препарированию — заполнение пропущенных данных методом медианы и редактирование выбросов (очистка). К наиболее критичным факторам, снижающим качество данных и требующим применения очистки, относятся: противоречивость, пропущенные значения, дубликаты, выбросы и аномальные значения, шум, ошибки ввода данных.

Очистка данных проводится непосредственно перед анализом. При этом основная очистка необходима после объединения, поскольку некоторые проблемы, например, дубликаты и противоречия, невозможно выявить до завершения консолидации данных. В сглаживании применяется алгоритм фильтров, который подавляет шумы в данных и быстрые изменения во временных рядах, обусловленные воздействием случайных факторов. В данном случае мы применяли частотный фильтр, использующий аппарат спектрального анализа. Для его работы ряд данных трансформируется с помощью преобразования Фурье в частотный спектр, из которого затем с помощью фильтра исключаются компоненты, порожденные нежелательными составляющими данных. Главный анализ данных происходит по алгоритму самоорганизующихся сетей Кохонена с построением в итоге интерактивной диаграммы методом СОК. На основной карте отображаются выделенные объекты в цветовой палитре по правилам нумерации кластеров методом СОК. На завершающей стадии происходит экспорт xml-файла и генерация карты в ArcGis. ГИС-проект в ArcGis позволяет менять, объединять или вырезать полученные кластеры в зависимости от задач, поставленных перед геологом. В результате группировка полученных данных и сравнение с эталонными объектами позволяют




Рис. 1. Сценарий автоматизированной обработки данных геофизических площадных работ с использованием искусственной нейронной сети Кохонена

генерировать карты в экспресс-режиме и включать их в прогноз.

Синяя ветка выполнения сценария направлена на исследование аномальных значений, отвечающих за ошибки в данных (погрешности измерений, неверная запись или считывание данных и т. п.), воздействие случайных, не поддающихся прогнозированию факторов, присутствие объектов инородных выборок (например, показания сломавшегося датчика), т.е. аномальными в нашей работе называются те значения, которые не укладываются в общую модель поведения анализируемых объектов. Обычно они сильно отличаются от окружающих данных и могут быть вызваны как ошибками измерений, так и некорректным вводом данных, или быть результатом их сильной изменчивости. Эта ветка сценария имеет следующую ценность. СОК выделяет среди аномальных данных точки измерений, которые в совокупности изображают изометричные объекты на конечной схеме с закономерной приуроченностью, такие, как кольцевые структуры, круговые объекты, короны круговых объектов.

Обработка методом СОК консолидированного файла с данными проведена по типичной схеме [Diachenko et al., 2019]. В результате кластеризации методом СОК объекты группировались на основе близости их свойств. Алгоритм функционирования СОК представляет собой один из вариантов кластеризации многомерных векторов. Важное отличие алгоритма СОК — в нем все нейроны (узлы, центры классов и т.п.) упорядочены в структуру в виде двумерной сетки. При этом в ходе обучения модифицируется не только нейрон-победитель, но и его соседи, но в меньшей степени. За счет этого СОК можно считать одним из эффективных экспресс-методов проецирования многомерного пространства в пространство с более низкой размерностью. В итоге применения этого алгоритма векторы, схожие в исходном пространстве, оказываются на полученной карте рядом.

При реализации алгоритма СОК задана шестиугольная конфигурация сетки при числе нейронов в сети 15x15. Некоторые источники рекомендуют использовать максимально возможное число нейронов в карте. При этом начальный радиус обучения (neighborhood) в значительной степени влияет на способность обобщения при помощи полученной карты [Карта, 2020]. В случае, когда число узлов карты превышает число примеров в обучающей выборке, успех использования алгоритма в большой степени зависит от подходящего выбора начального радиуса обучения. Однако в случае, когда размер карты составляет десятки тысяч нейронов, время, необходимое на обучение карты, обычно бывает слишком велико для решения практических задач. Таким образом, при выборе числа узлов необходимо достигать допустимого компромисса.

В ходе работы в части сценария, отвечающей за обучение, на первом этапе вычисляются последовательности коррекций векторов, представляющих собой нейроны. В первом приближении набор математических нейронов можно представить в виде сети, изготовленной из резины.

После нормализации входных векторов, образованных в результате распределения весов синаптических связей математических нейронов по формуле $w = [w_1, w_2, \dots, w_n]^T$, в случае активации сети в конкурентной борьбе побеждает тот нейрон, веса которого в наименьшей степени отличаются от соответствующих компонентов этого вектора. Для w -го нейрона-победителя выполняется отношение

$$d(x, w) = \min_{1 \leq i \leq n} d(x, w_i),$$

где $d(x, w)$ — расстояние между векторами x и w (в смысле выбранной метрики), а n — число нейронов. Образуется топологическая окрестность вокруг нейрона-победителя. Ее определенная энергетика уменьшается с течением времени. Нейрон-победитель и все нейроны, лежащие в пределах его окрестности, подвергаются адаптации, в ходе которой их векторы весов изменяются в направлении вектора x по правилу Кохонена. На каждом шаге обучения из исходного набора данных случайно выбирается один из векторов, а затем проводится поиск наиболее похожего на него вектора коэффициентов нейронов. При этом выбирается нейрон-победитель, который наиболее похож на вектор входов. Нейрон-победитель находится в центре топологической окрестности сотрудничающих нейронов. Под похожестью в этой задаче понимается расстояние между векторами, обычно вычисляемое в евклидовом пространстве. После того, как найден нейрон-победитель, выполняется корректировка весов нейросети. При этом вектор, описывающий нейрон-победитель, и векторы, описывающие его соседей в сетке, перемещаются в направлении входного вектора (рис. 2).

Для модификации весовых коэффициентов использовали формулу [Кохонен, 2008]:

$$w_{ji}(t+1) = w_{ji}(t) + r(t) [x_i^S(t) - w_{ji}(t)],$$

где t — номер эпохи (дискретное время), которая выполняет основное правило Кохонена; $x_i^S(t)$ — экземпляр i -й компоненты входного набора векторов в момент времени t ; $w_{ji}(t)$ — вес связи i -го входа j -го нейрона в момент времени t . При этом вектор $x_i^S(t)$ выбирается случайно из обучающей выборки на итерации t . Функция $r(t)$ называется функцией соседства нейронов, характеризующей их латеральные свойства. Эта функция представляет собой функцию, не возрастающую от времени и расстояния между нейроном-победителем и




Рис. 2. Последовательность организации нейросети (подстройка весов нейрона победителя и его соседей): *а* — этап инициации вектора, *б* — этап перетягивания узлов карты, *в* — результат перестраивания сетки по эластичной модели поведения ее узлов. Координаты входного вектора отмечены крестиком, координаты узлов карты после модификации — серые кружки. Вид сетки после модификации — штриховые линии (по [Самоорганизующиеся ..., 2020])

соседними нейронами в сетке. Эта функция разбивается на две части: 1) функция расстояния и 2) функция скорости обучения от времени, где r определяет положение нейрона в сетке: $r(t) = f(\|r_c - r_i\|, t) \cdot a(t)$, где $f(\|r_c - r_i\|, t)$ — функция расстояния между обучаемым j -м нейроном и его соседом, $a(t)$ — функция скорости обучения. Применена формула, наиболее используемая в подобных вычислениях из двух функций от расстояния:

$$h(d, t) = \begin{cases} \text{const}, & d \leq \sigma(t) \\ 0, & d > \sigma(t) \end{cases},$$

где d — линейное расстояние от нейрона-победителя до нейрона-соседа; $\sigma(t)$ — радиус обучения.

Лучший результат получается при использовании Гауссовой функции расстояния, которая представляет собой убывающую функцию от времени. Эту величину часто называют радиусом обучения, который выбирается достаточно большим на начальном этапе обучения и постепенно уменьшается так, что в конечном итоге обучается один нейрон-победитель. Наиболее часто используется функция, линейно убывающая от времени.

Функция скорости обучения $a(t)$ представляет собой функцию, убывающую от времени. Наиболее часто используются два варианта этой функции: линейная и обратно пропорциональная времени вида $a(t) = A/(t + B)$, где A и B — константы. Применение этой функции приводит к тому, что все векторы из обучающей выборки вносят примерно равный вклад в результат обучения. Самообучение состоит из двух основных фаз: на первоначальном этапе выбирается достаточно большое значение скорости обучения и радиуса обучения, что позволяет расположить векторы нейронов в соответствии с распределением примеров в выборке, а затем проводится точная подстройка весов, когда значения параметров скорости обучения много меньше начальных. В случае использования линейной инициализации первоначальный этап грубой подстройки может быть пропущен.

Таким образом, можно считать, что решена задача поиска похожих объектов и их группировки.

За счет этого СОК считается одним из методов проецирования многомерного пространства в пространство с более низкой размерностью. А обучение по этому методу напоминает натягивание эластичной сетки прототипов на массив данных из самообученной выборки. При использовании этого алгоритма векторы, схожие в исходном пространстве, оказываются рядом и на интерактивной СОК, затем определяется, какие объекты попали в какие узлы карты. Это также определяется ближайшим узлом — объект попадает в тот узел, который находится ближе к нему. В результате всех этих операций объекты со схожими параметрами попадут в один узел или в соседние узлы.

Так как алгоритм СОК сочетает в себе два основных направления — векторное квантование и проецирование (рис. 3), то в нашем случае основным применением этого алгоритма были поиск и анализ закономерностей в исходных данных.

Полученную карту можно представить в виде слоеного пирога из 11 карт обработки, каждый слой которого представляет собой раскраску, порожденную одной из компонент исходных данных: карта № 1 — VD_grav, карта № 2 — HG_grav и т.д., карта № 11 — матрица расстояний. Полученный набор раскрасок можно использовать для анализа закономерностей, имеющих между компонентами набора данных. После формирования карты мы получаем набор узлов, который можно отобразить в виде двумерной картинке. Каждому узлу карты можно поставить в соответствие шестиугольный участок, координаты которого определяются координатами соответствующего узла в решетке. Полученные раскраски в совокупности образуют атлас, отображающий расположение компонент, связи между ними, а также относительное расположение различных значений компонент. Визуализация карты Кохонена в различных разрезах осуществляется с помощью ряда сводных таблиц, где в столбцах координаты X , а в строках координаты Y , на их пересечении — сводные статистические значения, извлекаемые из соответствующего узла карты. В зависимости от цели сводной таблицы меняются только сводные статистические значения.




Рис. 3. Принципиальная схема работы СОК при обработке первичных данных площадных геофизических работ и их производных. VD_grav — гравиметрическая вертикальная производная; HG_grav — гравиметрический горизонтальный градиент; GRAV — исходное гравитационное поле; Tilt_grav — угол наклона гравитационного вектора; VD_mag — магнитометрическая вертикальная производная; AS_mag — аналитический сигнал магнитного поля (квадратный корень из суммы квадратов производных в направлениях x , y и z); HG_mag — магнитометрический горизонтальный градиент; Tilt_mag — угол наклона магнитного вектора; TMI — общий вектор магнитной индукции

Кластером будет группа векторов, расстояние между которыми внутри этой группы меньше, чем расстояние до соседних групп. Структура кластеров при использовании алгоритма СОК может быть отображена путем визуализации расстояния между опорными векторами (весовыми коэффициентами нейронов). При использовании этого метода чаще всего используется унифицированная матрица расстояний (u -matrix). При использовании этого метода вычисляется расстояние между вектором весов нейрона в сетке и его ближайшими соседями. Затем эти значения используются для определения цвета, которым будет отрисован этот узел.

Визуализация и анализ выделенных в результате выполнения нашего сценария кластеров, содержащих интервалы в каротажных данных, осуществляется в специально разработанной для этого книге MS Excel Visual.xlsm с подключенными макросами VBA. Для каждого узла и кластера отображается статистика в разрезе файлов по попавшим в них строкам: рассчитывается минимальное, средневзвешенное и максимальное значение каждого кластера, а также число строк, его составляющих. Кроме того, строится график, где в виде гистограммы отображается частотное распределение (левая вертикальная ось) значений выбранного параметра (по горизонтальной оси) и график «усатых ящиков» (диаграмма размаха) со средневзвешенными значениями для выяснения родства соседних кластеров.

На экспорте получены 225 классов с общим числом значений более 1,9 млн. Для оперативного анализа полученных классов использовали карты, сгенерированные в среде Processing [Processing, 2020] (рис. 4). В ArcGis 10.2 подгружены выделенные классы СОК с координатами (shp-файл)

для формирования пространственных данных растрового файла (flt-файл). Затем построена графическая схема распространения 225 классов СОК с разной вариацией цветовой гаммы. Дальнейшая обработка полученных кластеров в результате анализа методом СОК после особой «кластеризации транзакций» связана с геолого-поисковыми работами и представляет коммерческую ценность.

Результаты исследований и их обсуждение.

Специфика Норильского района определяется развитием крупных сульфидных медно-никелевых месторождений раннемезозойского возраста, связанных с дифференцированным ультрабазит-базитовыми интрузиями. Известные месторождения группируются в три рудных узла (рис. 5): Талнахский, Норильский и Имангдинский. Кроме того, по наличию рудопроявлений, выделяются Тальминский и Южно-Норильский потенциальные рудные узлы.

Из проанализированных более 1,9 млн значений автоматически СОК выделили кластерные группы объектов различного типа, две из которых интерпретированы как сопоставимые с известными геологическими объектами (рис. 5): 1) поля базальтов с рудоносными интрузиями, 2) кольцевая структура Болгохтохского массива. Для обоснования информативности кластерных групп, выделенных с помощью математического аппарата, проведена их корреляция с данными о геологии Норильского района и интрузиях основных месторождений в формате их общего пространственного развития.

Раннетриасовые интрузии норильского комплекса распространены преимущественно на крыльях Хантайско-Рыбинского и Курейско-Летнинского валов. Главная область их разви-




Рис. 4. Результирующие информационные карты выполненного алгоритма, реализующего метод СОК. Для примера выделен кластер № 222 с указанием его положения во всех типах геофизических данных




Рис. 5. Рудные узлы и кусты рудопроявлений Норильского района: 1 — область современного распространения вулканических образований; 2 — палеоизопакиты ниже-средненадеждинских лав, м; 3 — область распространения интрузий ниже-талнахского типа; 4 — Норильско-Хараелахский разлом; 5 — другие крупные разломы; 6 — зоны поперечных разломов; 7 — магмоактивные зоны вулканических образований; 8 — рудные узлы; 9 — кусты рудопроявлений

тия — Норильское и Хараелахское плато, а также Курейский рудный район (западная окраина плато Сыверма). Интрузии характеризуются наличием габбро-долеритов (габбро-диабазов) с ромбическим пироксеном, значительной дифференциацией и сульфидным медно-никелевым оруденением.

Талнахская интрузия разделяется на Северо-Западную ветвь, локализованную в девонских отложениях к западу от Главного шва Норильско-Хараелахского разлома, Северо-Восточную ветвь, залегающую в отложениях тунгусской серии к востоку от Главного шва, и Юго-Западную ветвь (также приуроченную к тунгусской серии), расположенную в пределах Центрального грабена. На участке северного окончания Центрального грабена Юго-Западная и Северо-Восточная ветви сливаются и далее на север продолжают в виде единого тела восточнее Главного шва. Северо-Западная ветвь непосредственного соединения с ветвями, названными выше, не имеет.

Полнодифференцированная часть интрузива, в разрезах которой присутствуют пикритовые габбро-долериты (основное тело) Северо-Запад-

ной ветви в плане имеет форму треугольника с округленными вершинами-выступами, одной относительно ровной (восточной) и двумя вогнутыми (северо-западной и юго-западной) сторонами. Длина основания этого условного треугольника вдоль Норильско-Хараелахского разлома составляет 10 км. Протяженность тела от восточной границы до окончания западного (Хараелахского) выступа — 8 км. Ширина выступов составляет 1–2 км. Восточная граница тела отчетливо контролируется Главным швом Норильско-Хараелахского разлома. В некоторых случаях граница удаляется от Главного шва как в западном (до 800 м), так и в восточном направлении (до 300 м).

Мощность интрузии в ее центральной части обычно составляет 50–150 м. Подошва приурочена к границе курейской и разведочнинской свит. При переходе от основного тела к краевым разрезам и дифференцированным апофизам (с исчезновением пикритовых габбро-долеритов) мощность сокращается до нескольких десятков метров (<50 м), а подошва интрузии воздымается. Наиболее резкое воздымание происходит на вы-

ступах. Здесь подошва интрузии переходит в верхи разведочнинской—низы мантуровской свиты, иногда в среднюю часть мантуровской свиты. Южный выступ целиком расположен в мантуровской свите, западный — поднимается в середину разведочнинской свиты еще в границах основного тела. На северном выступе граница подъема интрузива в разведочнинскую свиту и граница основного тела практически совпадают. На выступах воздымания интрузия сопровождается ее разветвлением на многочисленные апофизы.

Хараелахская интрузия расположена в западном борту Норильско-Хараелахского разлома в пределах нижнего (девонского) уровня локализации рудоносных интрузий. В составе Хараелахской интрузии по признакам морфологической самостоятельности и особенностям внутреннего строения были выделены две ветви — собственно Хараелахская и Северо-Западная. Тем не менее отметим, что некоторые исследователи объединяют ветви в одну, при этом названия отождествляются.

Интрузия Норильск-I представляет собой лентовидное тело, ориентированное в юго-западном направлении от Норильско-Хараелахского разлома, осложненного раздувами, пережимами и ответвлениями. В поперечном сечении форма интрузива корытообразная, с крутыми бортами и максимальной мощностью (250–350 м) в местах килевых выступов и мульдобразных прогибов подошвы. На севере интрузия состоит из двух ветвей — Западной и Восточной, соединяющихся обычно маломощной перемычкой, имеющей форму силла. На юге это единое тело с максимальной мощностью у юго-восточного борта. Общая протяженность массива около 10 км при ширине 1,5–2,5 км. Далее в южном направлении тело, круто изгибаясь в плане в форме подковы, переходит в Восточно-Норильскую ветвь. Горизонт локализации интрузии Норильск-I приурочен к границе тунгусской серии и пермо-триасовой туфолавоваы толщи. Среди известных в контурах выклинивания интрузии апофиз преобладают интрузивные тела в виде «рогов», «ушей», «сигнальных даек» (по Г.Л. Маслову). В меньшей степени развиты силлообразные апофизы.

Болгохтохская кольцевая структура представляет собой проекцию Болгохтохского штока гранодиоритов в геофизических полях, интерпретированных методом СОК. Шток прорывает осадочные породы нижнего—среднего палеозоя. Шток имеет диаметр 2,2–2,3 км, он прослежен бурением на глубину около 2 км, причем заметного изменения состава пород с глубиной не наблюдается. Анализ цирконов из этих пород показал согласующиеся значения возраста со средневзвешенными значениями $^{206}\text{Pb}/^{238}\text{U}$ и $^{207}\text{Pb}/^{235}\text{U}$ возраста, составляющими $228,9 \pm 0,3$ и $229,2 \pm 0,6$ млн лет соответственно, поэтому предполагается, что шток сформирован в связи с поздне триасовым

тектогенезом, определившим современный структурный план севера Сибирской платформы.

Болгохтохские гранодиориты приурочены к ядру антиклинальной складки, сложенной карбонатно-терригенными и гипсоносными отложениями ордовика, силура и девона. Кровля массива эродирована и скрыта под мощным чехлом рыхлых мезозойско-кайнозойских отложений. Шток сопровождается мощной (от 100 до 400 м) зоной роговиков и метасоматитов, наложенных на породы эндо- и экзоконтакта. Метасоматиты представлены альбититами, микроклинитами, форстеритовыми, пироксен-форстеритовыми, гранат-пироксеновыми скарнами, мусковит-кварцевыми и слюдными грейзенами. Последние проявляются в форме многочисленных маломощных жил, входящих в целом в состав штока. Мощность зон грейзенизации достигает 30 м.

С гранитоидным массивом связано медно-молибденовое оруденение, которое тесно ассоциирует с роговиками и метасоматитами: к кремнеземглиноземным роговикам тяготеют пиритовые, пирротиновые и галенит-сфалеритовые прожилки, к известковым скарнам — халькопиритовое и пиритовое оруденение, к магнезиальным — магнетитовое, реже халькопирит-пирротиновое оруденение; молибденитовая минерализация, реже халькопирит-пиритовая, локализуется в участках проявления грейзенизации.

Весьма схожий набор кластеров СОК, отражающих Болгохтохский шток гранодиоритов в виде Болгохтохской кольцевой структуры, сформировали на графическом изображении Пясинскую кольцевую структуру. Эта кольцевая структура отражает куполовидное поднятие, выделяемое по данным сейсморазведочных работ на глубине более 6,5 км (рис. 6, 7). Норильский, Вологодчанский и Талнахский рудные узлы расположены на участке сопряжения центриклиналей вулканоплутонических мульд с Пясинским куполовидным поднятием, которое разделяет Норильскую и Хараелахскую впадины. Это поднятие пересекает зона главного Норильско-Хараелахского разлома, контролирующего Талнахский и Норильский рудные узлы, и другие главные разломы (Фокинско-Тангаралахский, Далдыканский), контролирующими другие рудоносные интрузии с непромышленными месторождениями и рудопроявлениями.

Из анализа полученных результатов интерпретации больших объемов геофизических данных методом СОК можно предположить, что интрузии в Норильском металлогеническом районе внедрялись в приповерхностных условиях, будучи, по сути, субвулканическими и даже магматическими каналами для формировавшихся вулканитов. Интрузии, содержащие массивные сульфидные рудные тела, имеют форму ленты и размещены в осадочных породах от нижнего девона до верхней перми: интрузия Норильск-I

Рис. 6. Графическая схема Норильского металлогенического района распространения 225 классов СОК с разной вариацией цветовой гаммы по данным кластерного анализа методом самоорганизующихся карт Кохонена. Кольцевые структуры: 1 — Пясинская; 2 — Болгохтохская; интрузии: Н — Норильск-1, Х — Хараелахская, Т — Талнахская; А-Б — тектонический разрез по данным сейсморазведочных работ. Палитра автоматически раскрашена на основании выделенных 225 кластеров СОК





Рис. 7. Тектонический разрез по данным сейсморазведочных работ

локализована в тунгусской серии, состоящей из ритмично чередующихся угленосных терригенных осадочных образований и угольных пластов мощностью 0,5–15,0 м, а также в вышележащих вулканитах; Талнахская интрузия локализована в тунгусской серии и верхнедевонских доломитах, известняках и доломитовых мергелях каларганской свиты; Хараелахская интрузия — в доломитах, ангидритах, мергелях мантуровской свиты, в мергелях разведочинской и курейской свит нижнего девона. Рассматриваемый тип магматизма продуцирует достаточно «сухие» базальтовые магмы ($H_2O < 1$ масс.%), которые «прожигали» земную кору, образуя лавовые поля и маломощные силлы и дайки, а также излива-

лись на поверхность. Эти три интрузии могли в большом масштабе замещать перечисленные слои осадочной толщи.

При авторской обработке кластеров, полученных в результате анализа геофизических данных методом СОК, интерпретирована зависимость яркости цвета выделенных кластерных групп от глубины залегания осложненных магматизмом зон, выраженная по контрастности окраски изображения от близповерхностных до прослеживающихся на глубину обнаружения геофизическими методами. В то же время другая интерпретация возможной цветовой зависимости выделенных кластерных групп может быть связана с морфологией эпицентров магматизма и переходом с глу-

биной в ответвления, являющиеся рудоносными интрузиями.

Отсутствие цветового перехода от выделенных периферийных кластеров к более центральным связано с разделяющим их высокогорным рельефом, не позволяющим геофизическими методами получить достаточно данных для обработки.

Заключение. Использование кластеризации больших геофизических данных — достаточно быстрый и удобный способ их качественной интерпретации. Методом СОК (нейронной сети без учителя) вычислены в автоматическом режиме без исследователя-интерпретатора кластеры, которые характеризуют две кольцевые структуры, позволяющие иначе взглянуть на картину магматизма в Норильском металлогеническом районе.

В центре участка исследований корневые зоны интрузий норильского комплекса склоняются к внутренним частям Пясинской кольцевой структуры, где можно предполагать их глубинный очаг. Этот очаг можно рассматривать как плутон, дифференцированный от кислых гранитоидных пород, слагающих Болгохтохский шток, до предполагаемых базит-гипербазитовых разновидностей.

Таким образом, методом СОК решена одна из задач машинного обучения — разведочный анализ

данных. СОК распознала в разномасштабных и неоднородных данных уникальные кластеры, а также установила близость классов. Выстроена новая картина понимания структуры данных и уточнена модель их распределения. В данных распознаны классы, вследствие чего СОК решила задачи классификации без учителя — без заранее установленных понятий или моделей. Имея перед собой карту, полученную методом СОК, и зная хоть какую-то информацию о некоторой из части исследуемых объектов, можно достаточно достоверно судить о малоизвестных объектах на рассматриваемой территории. В случае, если стоит задача узнать, что из себя представляет новый объект, его можно в экспресс-режиме отобразить на карте и посмотреть на соседние. В результате можно извлекать информацию из базы данных, основываясь на нечетких характеристиках.

При дальнейших палеорекострукциях магмо-подводящих структур и картировании эпицентров их излияний необходимо учитывать особенности строения и вещественный состав образований. Рекомендуется провести ревизию других площадей Норильской металлогенической провинции методом самоорганизующихся карт Кохонена с последующей аналогичной интерпретацией.

СПИСОК ЛИТЕРАТУРЫ

Геология Норильской металлогенической провинции / Под ред. И.И. Никулина. М.: МАКС Пресс, 2020. 524 с.

Карта самоорганизации (Self-organizing map) на TensorFlow. [Электронный ресурс]. URL: <https://habr.com/ru/post/334810> (дата обращения: 25.08.2020).

Кириллов И.И., Морозов И.Н., Олейник А.Г. Разработка моделей экспресс-анализа обогащительных процессов на основе нейросетей и нечеткой логики // Тр. КНЦ РАН. 2013. № 5 (18). С. 152–159.

Кохонен Т. Самоорганизующиеся карты. Сер. Адаптивные и интеллектуальные системы / Пер. с англ. М.: Бинум, Лаборатория знаний, 2008. 656 с.

Никулин И.И., Савко А.Д. Железорудные коры выветривания Белгородского района Курской магнитной аномалии // Тр. НИИ геологии Воронежского гос. ун-та. 2015. Т. 85. 102 с.

Самоорганизующиеся карты Кохонена — математический аппарат. [Электронный ресурс]. URL: <https://basegroup.ru/community/articles/som> (дата обращения: 25.08.2020).

Diachenko V., Liashenko O.I., Ibrahim B.F. et al. Kohonen Network with Parallel Training: Operation Structure and Algorithm // Intern. J. Advanced Trends in Computer Sci. and Engineering. 2019. Vol. 8, N 1.2. P. 35–38. DOI: [org/10.30534/ijatse/2019/0681.22019](https://doi.org/10.30534/ijatse/2019/0681.22019).

Hu Z., Bodyanskiy Y.V., Tyshchenko O.K. et al. Kohonen Maps and Their ensembles for Fuzzy Clustering Tasks / Self-Learning and Adaptive Algorithms for Business Applications, Emerald Publ. Lim. 2019. P. 51–77. DOI: [org/10.1108/978-1-83867-171-620191004](https://doi.org/10.1108/978-1-83867-171-620191004).

Kalashnikov A.O., Nikulin I.I., Stepenshchikov D.G. Unsupervised geochemical classification and automatic 3D mapping of the Bolshetroitskoe high-grade iron ore deposit

(Belgorod Region, Russia) // Sci. Rep. 2020. 10. 17861. URL: <https://doi.org/10.1038/s41598-020-74505-y>.

Larose D.T., Larose C.D. Discovering Knowledge in Data: An Introduction to Data Mining. John Wiley & Sons, Inc., 2014. 336 p. DOI: [org/10.1002/9781118874059](https://doi.org/10.1002/9781118874059).

Processing IDE. [Электронный ресурс]. URL: <https://processing.org> (дата обращения: 25.08.2020).

Rodrigo B., Cavalcanti C. de, Pimentel B.A. et al. A multivariate fuzzy Kohonen clustering network // Intern. Joint Conf. on Neural Networks (IJCNN), 2019. [Электронный ресурс]. URL: <https://ieeexplore.ieee.org/document/8852243> (дата обращения: 25.08.2020). DOI: [10.1109/IJCNN.2019.8852243](https://doi.org/10.1109/IJCNN.2019.8852243).

Samanta S., Utkarsha S., Gour B. et al. Fast character recognition using Kohonen Neural Network // International Conference on Advanced Computation and Telecommunication (ICACAT). 2018. [Электронный ресурс]. URL: <https://ieeexplore.ieee.org/document/8933627> (дата обращения: 25.08.2020). DOI: [10.1109/ICACAT.2018.8933627](https://doi.org/10.1109/ICACAT.2018.8933627).

Silva Iv.N. da., Spatti D.H., Flauzino R.An. et al. Self-organizing Kohonen networks / Artificial Neural Networks. Springer Internat. Publ. Switzerland. 2017. P. 157–172. DOI: [org/10.1007/978-3-319-43162-8_8](https://doi.org/10.1007/978-3-319-43162-8_8).

Todeva E., Knoke D., Keskinova D. Multi-stage clustering with complementary structural analysis of 2-mode networks // ASONAM'19: Proceed. of the 2019 IEEE/ACM Intern. Conf. on Advances in Social Networks Analysis and Mining. 2019. P. 771–778. DOI: [org/10.1145/3341161.3344781](https://doi.org/10.1145/3341161.3344781).

Поступила в редакцию 21.09.2019

Поступила с доработки 30.06.2020

Принята к публикации 30.06.2020