

УДК 004.891.3; 550.8.053

НЕЙРОСЕТЕВОЙ КЛАСТЕРНЫЙ АНАЛИЗ ПЛОЩАДНЫХ ГЕОФИЗИЧЕСКИХ ДАННЫХ РУДОНОСНОГО ХИБИНО-ЛОВОЗЁРСКОГО ВУЛКАНО-ПЛУТОНИЧЕСКОГО КОМПЛЕКСА (КОЛЬСКИЙ П-ОВ) МЕТОДОМ САМООРГАНИЗУЮЩИХСЯ КАРТ КОХОНЕНА

© 2021 г. И.И. Никулин¹, А.А. Самсонов²

¹ ООО “Норильскгеология”, г. Санкт-Петербург, Россия

² Московский государственный университет имени М.В. Ломоносова, г. Москва, Россия

Автор для переписки: И.И. Никулин (e-mail: iinikulin@gmail.com)

Описана методика автоматической экспресс-интерпретации данных площадных геофизических исследований на примере Хибино-Ловозёрского вулканоплутонического комплекса, в рамках которой построена комплексная геофизико-математическая модель, состоящая из пятнадцати уровней иерархии и базирующаяся на использовании математического аппарата искусственных нейронных сетей. В обработке данных геофизических съемок применен метод самоорганизующихся карт Кохонена. Это математический аппарат нечеткой логики, искусственная нейронная сеть которого обучается без учителя. Обосновано формирование групп кластеров, характеризующих в наибольшей степени возможные связи между многомерными геофизическими данными, и проанализировано наличие взаимосвязей между ними путем выявления корреляционных зависимостей. Проведен анализ различных геофизических трансформант с применением самоорганизующихся карт Кохонена. Искусственной нейронной сетью вычислены кластеры, которые в результате исследования отражают картину крупной палеозойской рудно-магматической системы на северо-востоке Фенноскандинавского щита, объединяющей Хибинский и Ловозёрский плутоны, Кургинскую интрузию, вулканогенные образования и многочисленные рои щелочных даек. 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 и их параметры применительно к главному кольцу Хибинского массива, контролирующему редкоземельно-титан-алюмо-фосфорные месторождения, и Федоро-Панским Тундрам (платино-паладиевые месторождения). Предложены объекты, потенциальные для геологического изучения вблизи Ловозёрского эвдиалитового циркон-редкоземельного месторождения. Проведенное экспериментальное исследование подтвердило адекватность построенной модели и эффективность ее использования для экспресс-анализа геофизических данных и принятия решений в геолого-поисковых задачах.

Ключевые слова: гравиразведка, магниторазведка, иерархическая модель, искусственная нейронная сеть, карта Кохонена, нечеткая логика, кластерный анализ.

Введение

Существует множество способов автоматической обработки больших массивов данных, но универсального метода для изучения данных геофизических площадных работ до сих пор не создано. Комплексный анализ и интерпретация геофизических полей, наряду с непосредственным объединением 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

исследуемых площадей, то комплексная интерпретация геополей ориентирована на количественную оценку геометрических (глубины, формы и элементов залегания) и физических (физические свойства) параметров искоемых объектов – источников, образующих аномалии. Решение задач комплексного анализа осуществляется как при наличии, так и при отсутствии эталонных объектов.

Отсутствие эталонных объектов, на которых проводится оценка статистических характеристик и информативности изучаемых признаков, приводит к необходимости разработки алгоритмов обработки комплекса данных на принципах самообучения – распознавании образов без обучения на эталонных объектах. Самообучение является эффективным инструментом, когда связи между данными неочевидны или кажутся отсутствующими, потому что их слишком много [Hu, Bodyanskiy, Tyshchenko, 2019; Cavalcanti et al., 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 сущности задачи, поскольку в конечном итоге площадь исследования разделяется на конкретное число однородных по комплексу признаков классов.

Среди существующих 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.

Одна из разновидностей нейросетевых алгоритмов, разработанных по методу Т. Кохонена [Кохонен, 2008; Самоорганизующиеся ...] – самоорганизующиеся карты (СОК, в английской литературе – *SOM (Self Organizing Maps)*). Основным отличием данной технологии от иных нейросетей, обучаемых по алгоритму обратного распространения, является использование метода самообучения без учителя, то есть результат обучения зависит только от структуры входных данных [Silva et al., 2017]. Нейронные сети такого типа часто применяются для решения самых разных задач – от восстановления пропусков в данных до анализа данных и поиска закономерностей, например, в финансовой задаче [Hu, Bodyanskiy, Tyshchenko, 2019], в горно-обогательном процессе [Кириллов, Морозов, Олейник, 2013], в обработке тысяч анализов сплошного геохимического опробования керна при технологической типизации руд [Никулин, Савко, 2015; Kalashnikov, Nikulin, Stepenshchikov, 2020]. Особенностью метода самоорганизующихся карт Кохонена является его устойчивость к зашумленным данным, быстрому и неуправляемому самообучению, возможности упрощения многомерных входных данных с помощью визуализации. В представленном исследовании с помощью этого метода обработано огромное количество данных с преимущественно нечеткими связями, полученных в результате площадных геофизических работ в масштабе 1:50000. Реорганизация многомерных данных в двумерные диаграммы нечетких связей (карты Кохонена) дает больше оснований для принятия дальнейших решений по анализируемым объектам [Cavalcanti et al., 2019; Todeva, Knoke, Keskinova, 2019].

В настоящее время нам представляется, что возможно использовать нейронные сети, которые без значимых финансовых и временных затрат позволяли бы в экспресс-режиме обрабатывать большие объемы данных, и тем самым направляли внимание даже самого неопытного интерпретатора на нюансы исследуемого материала. В научном мире подобные исследования называются *Data-mining*. Они предполагают поиск скрытой информации в околорезкобесконечном массиве сырых (необработанных) данных любой размерности (1D, 2D, 3D, 4D и т.д.), а методы их реализации становятся все более простыми и быстрыми [Larose, Larose, 2014; Samanta et al., 2018].

В настоящей работе нейросеть состоит всего из двух слоев – входного (распределительного) и выходного, называемого также слоем Кохонена. В нейросети Кохонена каждый нейрон входного слоя связан со всеми нейронами выходного, а внутри слоев таких связей нет. На нейроны входного слоя подаются векторы признаков кластеризуемых объектов. Количество 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”, то есть 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. Метод СОК подразумевает использование упорядоченной структуры нейронов, располагающихся в узлах двумерной сетки с прямоугольными (четырёхугольными) или шестиугольными ячейками. Для шестиугольной сетки расстояние между нейронами ближе к евклидовому расстоянию, чем для четырёхугольной сетки. Расположенные в узлах двумерной сетки нейроны взаимодействуют между собой. Величина этого взаимодействия определяется расстоянием между нейронами на карте. Количество нейронов в сетке определяет степень детализации результатов работы алгоритма, и, в конечном счете, от этого зависит правильность обобщающей способности карты. На практике обобщающая способность, являющаяся важнейшим свойством аналитической модели, приобретаемым в процессе обучения нейросети Кохонена – это способность аналитической модели, построенной на основе СОК, выдавать правильные результаты не только для примеров, участвовавших в процессе обучения, но и для любых новых, которые в нем не участвовали.

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.

Методика

Авторами были собраны данные геофизических площадных работ масштаба 1:50 000, выполненных в пределах Хибино-Ловозёрского вулcano-плутонического комплекса Кольского полуострова. Анализировались следующие данные:

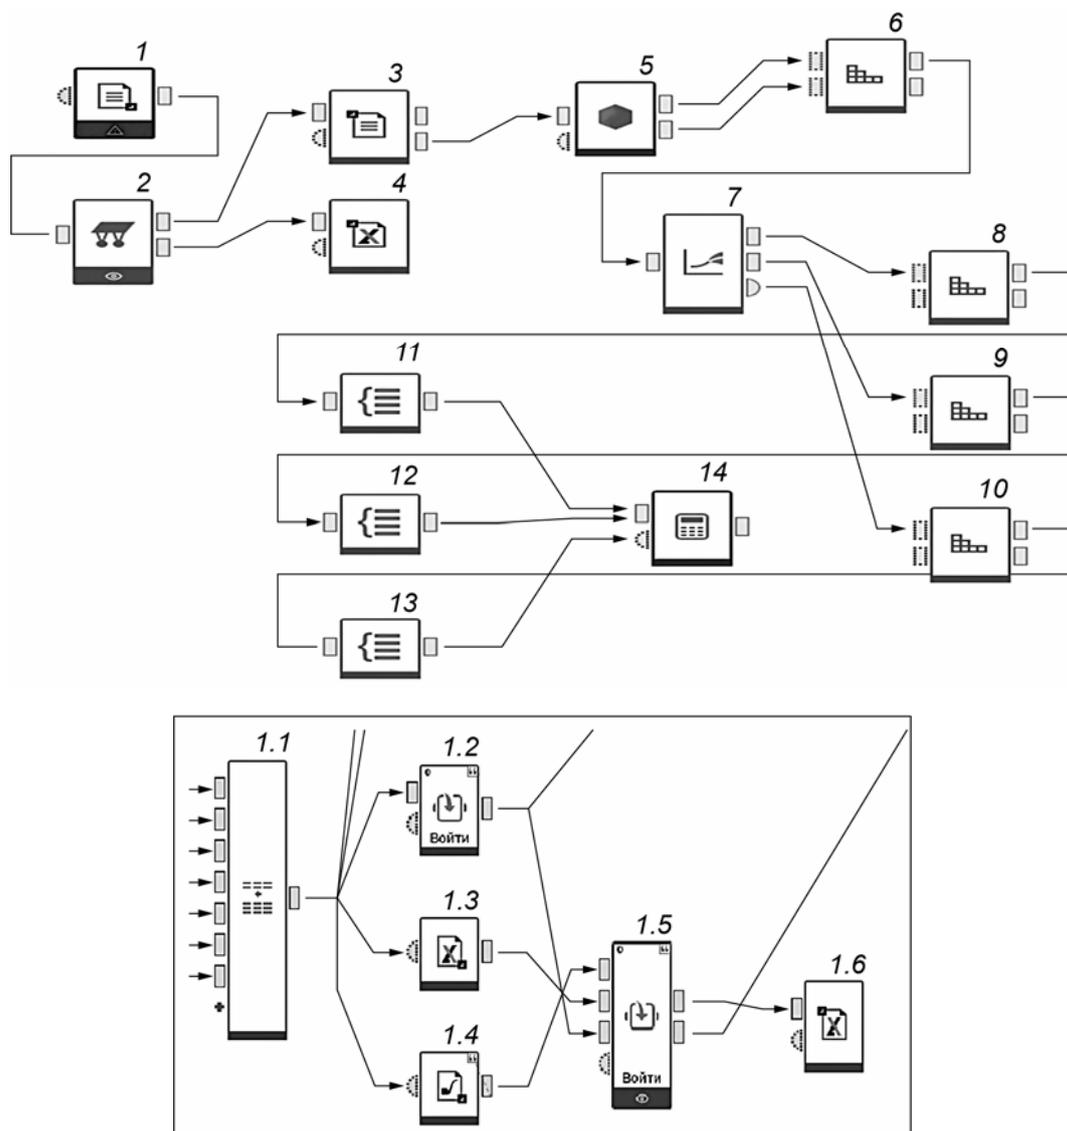
- *Mag* – аномальное магнитное поле;
- *Mag_lok* – локальная составляющая аномального магнитного поля;
- *dxu_mag* – полный горизонтальный градиент магнитного поля;
- *As_mag* – аналитический сигнал (квадратный корень из суммы квадратов производных по направлениям x , y и z : $a_{sig} = \sqrt{dx^2 + dy^2 + dz^2}$), который использован при обнаружении краев тел аномальных (магнитных) источников, особенно там, где остаточная намагничённость и/или низкая магнитная широта затрудняет интерпретацию;

- *Grav* – аномальное гравитационное поле;
- *Grav_lok* – локальная составляющая аномального гравитационного поля;
- *As_grav* – аналитический сигнал (трансформанта гравитационного поля);
- *dxu_grav* – полный горизонтальный градиент;

– *AGP_grav* – автоматическая коррекция усиления, использованная для автоматической компенсации усиления сигнала в гриде (поправка применяется после выделения полезного сигнала и фона во входном гриде для заданного размера окна к компоненту сигнала, чтобы выровнять его амплитуду по гриду).

Общий сценарий анализа геофизической информации методом искусственной нейронной сети состоит из четырех основных этапов и блоков-алгоритмов их реализации (рис. 1, *вверху*): сбор данных (блок-алгоритм 1); обработка методом СОК консолидированного файла с данными (блок-алгоритм 2); экспорт *CSV*-файла и генерация карты в *ArcGis* (блоки-алгоритмы 3–5); группировка полученных данных и сравнение с эталонными объектами для генерации карт и их включения в прогноз (блоки-алгоритмы 6–14). Исходные текстовые файлы с данными геофизических работ собираются по алгоритму, функционирующему внутри всего сценария реализации СОК (рис. 1, *внизу*). Затем *CSV*-файл с обработанными данными подается на вход нейронной сети, обрабатывающей информацию.

Обработка методом СОК консолидированного файла с данными проведена по типичной схеме, изложенной в [Diachenko et al., 2019]. В результате кластеризации методом СОК объекты разгруппировались на основе близости их свойств.



Алгоритм функционирования СОК представляет собой один из вариантов кластеризации многомерных векторов. Важным отличием этого алгоритма является то, что 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 метод самоорганизующихся карт Кохонена может считаться одним из эффективных экспресс-методов проецирования многомерного пространства в пространство с более низкой размерностью. После применения алгоритма СОК вектора, схожие в исходном пространстве, на получаемой карте оказываются рядом.

В представляемом исследовании при реализации алгоритма СОК задавалась шестиугольная конфигурация сетки с количеством нейронов в сети 15×15 . Принимая во внимание накопленный опыт, рекомендуется использовать максимально возможное количество нейронов в карте для получения большей детализации, ограничиваясь только плотностью сетей грави- и магниторазведки. При этом начальный радиус обучения (в англоязычной литературе – *neighborhood*) в значительной степени влияет на способность обобщения при помощи получаемой карты. В случае, когда количество узлов карты превышает количество примеров в обучающей выборке, успех использования алгоритма в большой степени зависит от подходящего выбора начального радиуса обучения. Однако, в ином случае, когда размер искусственной нейронной сети составляет десятки тысяч нейронов, время, требуемое на обучение, обычно бывает слишком велико для решения практических задач. Таким образом, необходимо стремиться к достижению допустимого компромисса при выборе количества узлов.

Теоретическая часть вышеизложенного подробно описана в открытых источниках, а также в переведенной на русский язык монографии Т. Кохонена [2008].

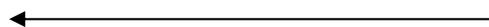


Рис. 1. Вверху: сценарий автоматизированной обработки данных геофизических площадных работ. Блоки-алгоритмы: 1 – консолидация входных данных; 2 – реализация самоорганизующихся нейронных сетей Кохонена; 3 – экспорт файла для *ArcGis*; 4 – экспорт файла с числовыми значениями нейросетевого анализа; 5 – информационная карта в *ArcGis* с кластерами; 6 – кластеризация транзакций; 7 – сортировка эталонных классов; 8–10 – выделение классов кольцевых структур (8), линеаментов (9), скрытых структур (10); 11 – сортировка данных для кольцевых структур; 12 – сортировка данных для линеаментов; 13 – сортировка данных для скрытых структур; 14 – построение прогнозной карты

Внизу: фрагмент алгоритма консолидации входных данных. Блоки-алгоритмы: 1.1 – объединение информации из всех входящих файлов; 1.2 – выявление аномальных значений; 1.3 – экспорт файла с объединенными данными; 1.4 – статистический анализ данных; 1.5 – разметка аномальных групп значений через кластеризацию с последующей группировкой до укрупненных классов; 1.6 – сохранение файла с результатами сопоставления

Fig. 1. Above: scenario of automatic data processing of geophysical areal works. Algorithm blocks: 1 – consolidation of input data; 2 – implementation of self-organizing Kohonen neural networks; 3 – file export for *ArcGis*; 4 – export of a file with numerical values of neural network analysis; 5 – information map in *ArcGis* with clusters; 6 – clustering of transactions; 7 – sorting of reference classes; 8–10 – identification of classes of ring structures (8), lineaments (9), hidden structures (10); 11 – sorting data for ring structures; 12 – sorting data for lineaments; 13 – sorting data for hidden structures; 14 – building a forecast map

Below: a fragment of the input data consolidation algorithm. Algorithm blocks: 1.1 – combining information from all incoming files; 1.2 – detecting anomalous values; 1.3 – export of a file with combined data; 1.4 – statistical data analysis; 1.5 – marking anomalous groups of values through clustering with subsequent grouping to enlarged classes; 1.6 – saving a file with results of comparison

Так как алгоритм СОК сочетает в себе два основных направления – векторное квантование и проецирование (рис. 2), то в рассматриваемом случае он применялся в основном для поиска и анализа закономерностей в исходных данных. Алгоритм выполнялся с параметром минимальной ошибки в 95%, что обычно отражается на количестве эпох пересамообучения (пока не будет достигнуто обозначенное качество). В настоящей работе нейросетевой кластерный анализ Карело-Кольского региона с выделением в нем Хибино-Ловозёрского вулcano-плутонического комплекса на процессоре *Intel i5-4430* занял чуть более 7.5 ч.

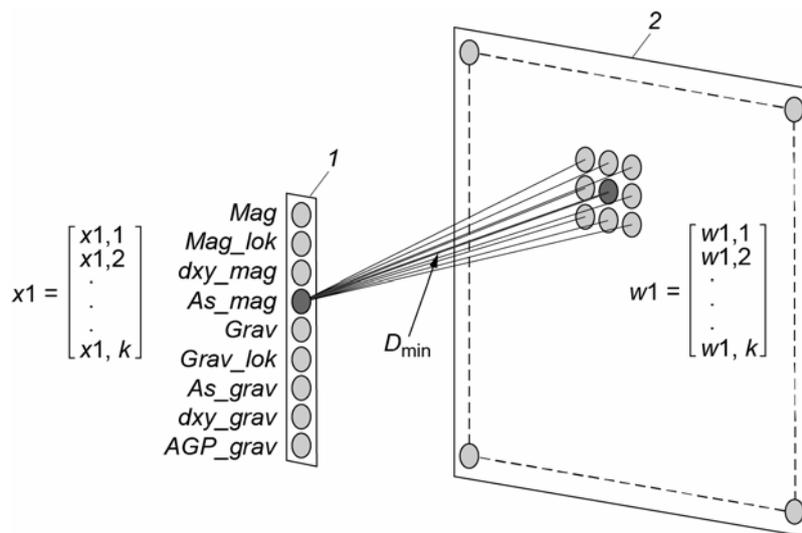


Рис. 2. Принципиальная схема работы нейросети Кохонена при обработке первичных данных геофизической разведки и их производных. 1 – входной слой, на который подаются векторы признаков кластеризуемых объектов x_1 в многомерном измерении; 2 – выходной слой, в котором проецируются w_1 -признаки на двумерное измерение. Кружки – символы математического аппарата нейрона (каждый кружок отвечает своему отдельному каналу информации – *Mag*, *Mag_lok*, *dxy_mag*, *As_mag*, *Grav*, *Grav_lok*, *As_grav*, *dxy_grav*, *AGP_grav* – комментарии см. в тексте). Темно-серый кружок – нейрон-победитель с наименьшим расстоянием между слоями (D_{\min}); штриховые линии – схематическая связь между угловыми узлами решетки размером 15×15 (вне масштаба)

Fig. 2. A schematic diagram of the Kohonen neural network operation in the processing of primary geophysical survey data and their derivatives. 1 – input layer, where vectors of features of clustered objects x_1 are supplied in multidimensional dimension; 2 – output layer, where w_1 -features are projected onto a two-dimensional dimension. Circles are symbols of the mathematical apparatus of a neuron (each circle corresponds to its own separate channel of information – *Mag*, *Mag_lok*, *dxy_mag*, *As_mag*, *Grav*, *Grav_lok*, *As_grav*, *dxy_grav*, *AGP_grav*). Dark gray circle is a winning neuron with the smallest distance between the layers (D_{\min}); dashed lines are schematic connection between corner nodes of the lattice 15×15 (out of scale)

Кластер – это группа векторов, расстояние между которыми внутри группы меньше расстояния до соседних групп. Структура кластеров при использовании алгоритма СОК может быть отображена путем визуализации расстояния между опорными векторами (весовыми коэффициентами нейронов). При применении этого метода чаще всего сначала используется унифицированная матрица расстояний (*u-matrix*), после чего вычисляется расстояние между вектором весов нейрона в сетке и его ближайшими соседями. Далее полученные значения используются для определения цвета, которым этот узел будет отображаться на карте.

Получаемую карту кластеров можно воспроизвести в виде “слоеного пирога” из одиннадцати информационных карт обработки (рис. 3), каждый слой которого представляет собой раскраску, порожденную одной из компонент исходных данных.

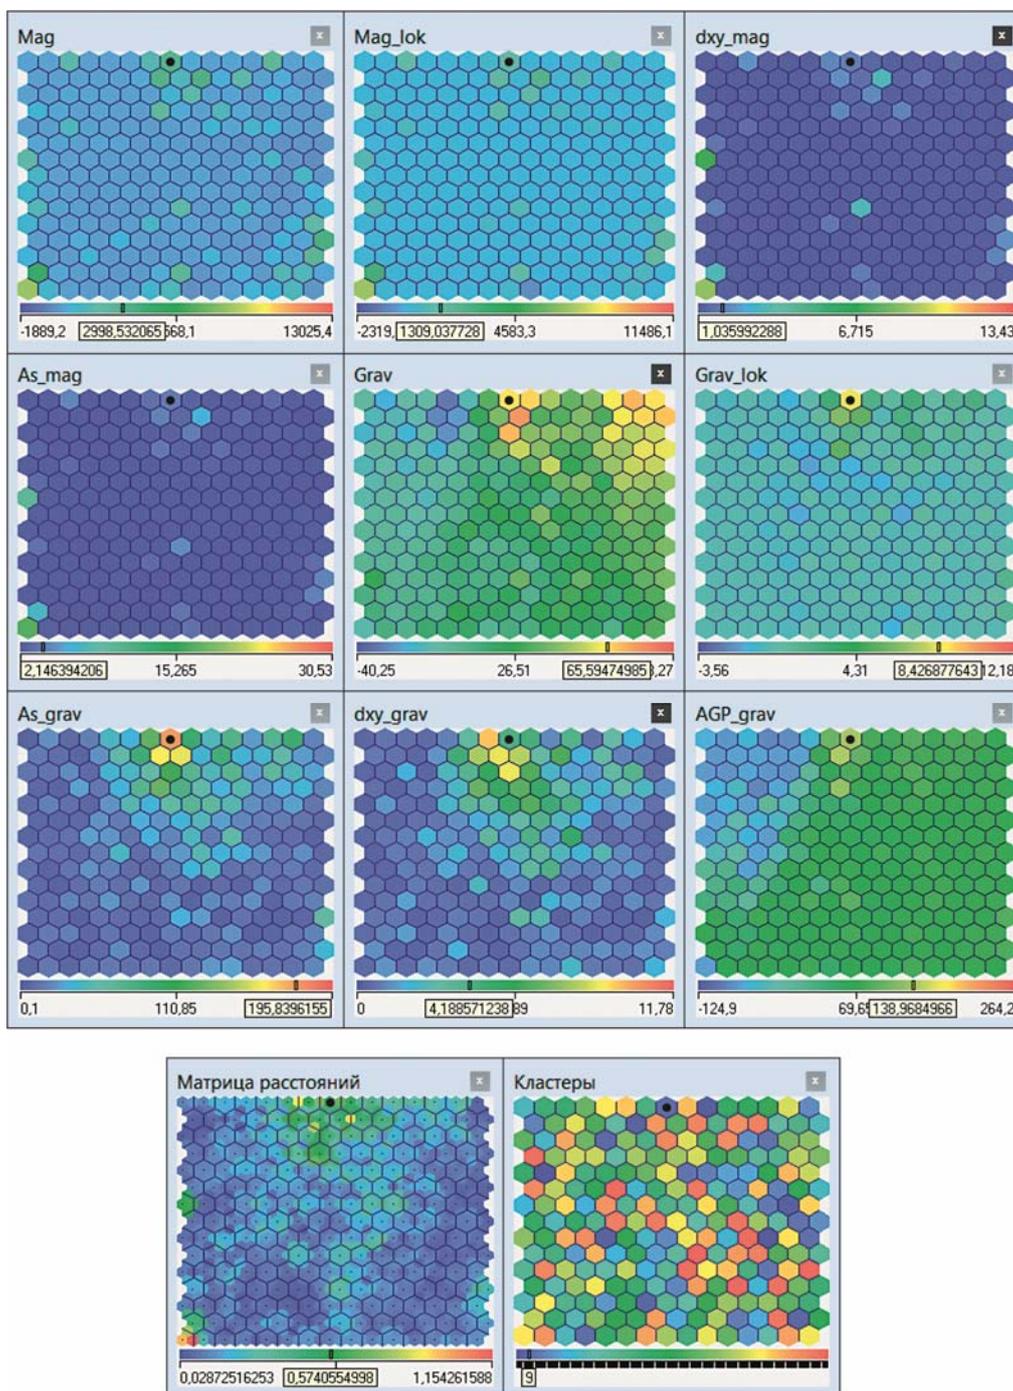


Рис. 3. Информационные карты, полученные в результате применения метода самоорганизующихся карт Кохонена (вверху), матрица расстояний между кластерами и карта кластеров (внизу). Черным кружком для примера отмечен кластер № 9

Fig. 3. Information maps obtained as a result of the application of the method of self-organizing Kohonen maps (above), matrix of distances between clusters and map of clusters (below). As an example, cluster no. 9 is marked with a black circle

Набор раскрасок может использоваться для анализа закономерностей, имеющихся между компонентами набора данных. После формирования карты образуется набор узлов, который можно воспроизвести в виде двумерной картинке. Каждому узлу карты ставится в соответствие шестиугольный участок, координаты которого определяются координатами соответствующего узла в решётке. Полученные раскраски в совокупности образуют атлас, отображающий расположение компонент, связи между ними, а также относительное расположение различных значений компонент. Визуализация карты Кохонена в разных разрезах реализуется с помощью ряда сводных таблиц, где в столбцах указаны координаты X , в строках – координаты Y , на пересечении – их сводные статистические значения, извлекаемые из соответствующего узла карты. В зависимости от цели сводной таблицы меняются только сводные статистические значения.

Визуализация и анализ кластеров, выделенных в результате выполнения представленного выше сценария, 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: считается минимальное, средневзвешенное и максимальное значение каждого кластера, а также количество составляющих его строк. Полученные новые данные являются терминологическими множествами. Кроме этого, строится график, отображающий в виде гистограммы частотное распределение значений выбранного параметра, и диаграмма размаха со средневзвешенными значениями для выяснения родства соседних кластеров.

В представляемом исследовании с помощью методов нечеткой логики СОК на выходе получены 225 кластеров с общим количеством значений геофизических чисел, превышающим 1.04 млн, на основе которых в *ArcGis 10.2* строилась геофизико-математическая модель в виде двумерной карты кластеров. Выделенные классы СОК с координатами (*shp*-файл) были подгружены для формирования пространственных данных растрового файла (*flt*-файл). После этого была построена графическая схема распространения 225 классов СОК с различной вариацией цветовой гаммы. Для каждой группы кластеров были сформированы в виде сводной таблицы терминологические множества, представляющие собой статистические данные по гравиразведке и магниторазведке.

Дальнейшая обработка полученных кластеров в результате анализа методом СОК после особой “Кластеризации транзакций” связана с геолого-поисковыми работами и представляет коммерческую ценность. Так, к примеру, был задан вид функций принадлежности ранее неизвестных геологических объектов по новым проинтерпретированным данным. Входные показатели-репрезентанты этих новых данных как терминологические множества применительно к главному кольцу Хибинского массива, контролирующему редкоземельно-титан-алюмо-фосфорные месторождения, и Федоро-Панским Тундрам (платино-паладиевые месторождения), являются физико-математической поисковой моделью, на основе которой могут быть построены двумерные карты кластеров в *ArcGis*.

Результаты исследования

Как отмечено выше, из автоматически проанализированных методом СОК более чем 1.04 млн значений геофизических чисел были выделены кластерные группы различных типов геологических объектов Хибино-Ловозёрского вулcano-плутонического комплекса, три из которых интерпретированы как сопоставимые с известными рудными полями Хибинского массива, включающими двенадцать месторождений и рудопроявлений (рис. 4).

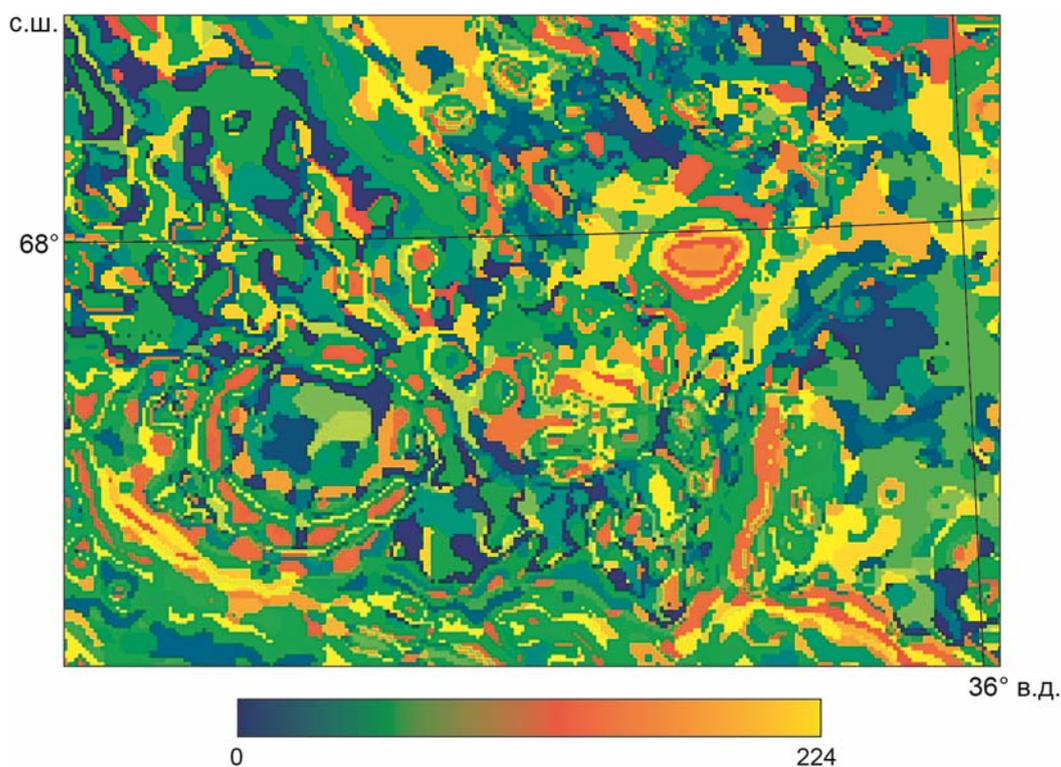


Рис. 4. Геофизико-математическая модель распределения геофизических кластеров в пределах Хибино-Ловозёрского вулcano-плутонического комплекса, полученная методом самоорганизующихся карт Кохонена. *Внизу:* шкала нумерации 225 выделенных кластеров

Fig. 4. Geophysical-mathematical model of the distribution of geophysical clusters within the Khibiny-Lovozero volcano-plutonic complex, obtained by the method of self-organizing Kohonen maps. *Below:* numbering scale of 225 allocated clusters

Для обоснования информативности кластерных групп, определенных с помощью математического аппарата, была проведена их корреляция с данными по геологии Хибинского массива и структурами основных месторождений и рудопроявлений Главного кольца в формате их общего пространственного развития.

Крупнейший в мире Хибинский щелочной массив, имеющий площадь около 1327 км², расположен в центральной части Кольского полуострова на контакте пород зеленокаменного пояса Имандра-Варзуга с метаморфическими комплексами Кольско-Норвежского мегаблока (рис. 5). В плане Хибинский массив имеет овальную форму с длиной 45 км по широтной оси и 35 км по меридиональной. В рельефе горный комплекс пород массива резко возвышается над окружающей низменностью в виде подковообразного плато с высотой около одного километра (рис. 5, *вверху справа*). По данным геофизических исследований [Шаблинский, 1963], субвертикальный вблизи поверхности контакт пород массива с вмещающими породами на юге и западе с глубиной выполаживается; на севере и востоке это выполаживание менее значительно. Ввиду такой формы, на глубине 10 км площадь массива составляет менее половины от его площади на дневной поверхности.

Около 70 % площади массива занимают нефелиновые сиениты, разделяемые большинством исследователей на две примерно равные по площади части – фойяиты (в центре) и хибиниты (вокруг них), между которыми расположен зональный комплекс пород Главного кольца.

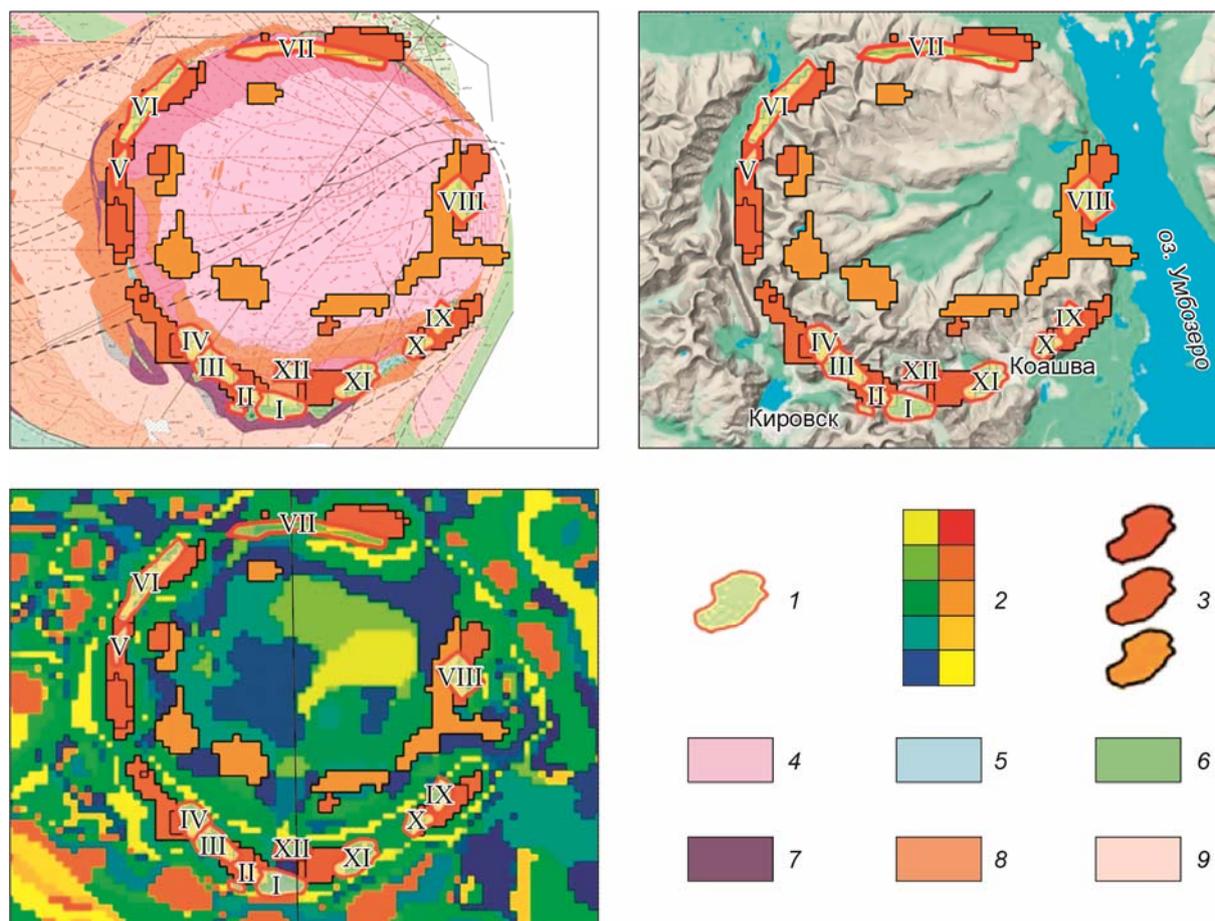


Рис. 5. Проявленность рудоносных комплексов Хибинского массива в результатах кластерного анализа площадных геофизических данных методом самоорганизующихся карт Кохонена. *Вверху:* геологическая схема Хибинского массива (слева) и схема Хибинского массива на террейне с рельефом (справа). *Внизу:* схема сопоставления кластеров методом СОК

1 – участки месторождений и рудопроявлений (I – Апатитовый Цирк, II – Плато Расвумчорр, III – Юкспорское, IV – Кукисвумчорр, V – Куэльпор, VI – Партомчорр, VII – Лявочорр-Валепахк-Намуайв, VIII – Тульйокское, IX – Олений Ручей, X – Ньоркпахк, XI – Коашва, XII – Эвеслогчорр); 2 – кластерные группы; 3 – выделенные кластеры, характеризующие апатитовые рудные зоны от близкоповерхностных с пологим падением 30–40° до прослеживающихся на глубину обнаружения метода (по степени яркости); 4–9 – горные породы: фойялиты (4), йолиты-уртиты трахитоидные (5), уртиты полевошпатовые (6), ювиты трахитоидные/йолиты полевошпатовые (7), рисчорриты (8), хибиниты (9)

Fig. 5. Manifestation of ore-bearing complexes of the Khibiny massif in the results of cluster analysis of areal geophysical data using Kohonen self-organizing maps. *Above:* geological scheme of the Khibiny massif (left) and the map of the Khibiny massif on a terraine with a relief (right). *Bottom:* the sketch of cluster comparison by the SOM method

1 – areas of deposits and ore occurrences (I – Apatite circus, II – Rasvumchorr Plateau, III – Yuksporskoe, IV – Kukisvumchorr, V – Kuelpor, VI – Partomchorr, VII – Lyavochorr-Valepakhk-Namuiv, VIII – Tul'yokskoe, IX – Oleniy Ruchey, X – Nyorpakhk, XI – Koashva, XII – Eveslogchorr); 2 – cluster groups; 3 – identified clusters characterizing apatite ore zones from near-surface ones with a gentle dip of 30–40° to those traced to the detection depth of the method (in terms of brightness); 4–9 – rocks: foyalites (4), trachytoid yolites-urtites (5), feldspar urtites (6), trachytoid/feldspar yolites (7), rischorrites (8), khibinite (9)

Основной объем Главного кольца занимает комплекс ийолит-уртитов и высококальциевых нефелиновых сиенитов-рисчорритов. Все хибинские апатито-нефелиновые и титанито-apatито-нефелиновые месторождения и рудопроявления приурочены к приконтактной с рисчорритами части ийолит-уртитовой толщи Главного кольца, где они группируются в пределах трех рудных полей – юго-восточного, юго-западного и северного (рис. 5, *вверху слева*). Месторождения в пределах каждого из этих полей имеют сходное строение.

В юго-западном сегменте месторождения представляют собой части единой рудной зоны апатито-нефелиновых пород, протянувшейся от г. Кукисвумчорр до г. Коашва (месторождения Кукисвумчорр, Юкспорское, Плато Расвумчорр, Апатитовый цирк, Эвеслогчорр). Месторождения юго-восточного рудного поля (Коашва, Ньоркпахк и Олений Ручей) представлены штокверками линзово-прожилковых тел, а месторождения северного рудного поля (Партомчорр, Куэльпор, рудопроявления Лявочорр-Валепакх-Намуайв) – отдельными пластообразными телами апатито-нефелиновых и апатито-титанитовых пород [*Иванюк и др.*, 2009]. Карбонатитовый комплекс, приуроченный к восточной части фойяитового ядра Хибинского массива (Тульйокское рудопроявление), относится к четвертому рудному полю.

Месторождение Коашва расположено на восточных отрогах одноименной горы и в долине р. Вуоннемйок. Общее простирание рудной зоны северо-восточное 60° . Вблизи поверхности рудная зона имеет пологое падение под углом $20\text{--}30^\circ$; на глубине $1.5\text{--}2.0$ км угол падения увеличивается до $40\text{--}50^\circ$. На юго-западном фланге месторождения апатито-нефелиновые породы слагают $5\text{--}8$ субпараллельных протяженных слоев мощностью до 10 м, объединенных в устойчиво выраженную зону с углом падения $\sim 30^\circ$ в направлении к центру массива.

Месторождение Кукисвумчорр, разрабатываемое открытым и подземным способами, в своей южной части переходит в месторождение Юкспор и далее в месторождения Расвумчорр и Апатитовый Цирк, составляя вместе с ними непрерывную залежь протяженностью около 12 км. Линза апатито-нефелиновых пород месторождения Кукисвумчорр имеет мощность от 40 м на северном фланге до 180 м на южном и погружается под углом $26\text{--}32^\circ$ в северо-восточном направлении.

Месторождение Партомчорр представлено протянувшейся от г. Куэльпор до г. Лявочорр шестикилометровой рудной зоной, которая имеет весьма незначительную общую мощность ($50\text{--}150$ м, включая внутрирудные прослои ийолит-уртитов). Как и на всех других месторождениях, пологое падение пород под углом $30\text{--}40^\circ$, отмечаемое вблизи поверхности, на глубине порядка 300 м сменяется более крутым под углом $50\text{--}60^\circ$.

Общая закономерность массива – переход монолинзовых месторождений в штокверковые на более глубоких горизонтах. Мощность рудных зон экспоненциально возрастает по мере их приближения к поверхности. В то же время, в пределах отдельных месторождений наиболее мощная часть рудной зоны расположена не на самой поверхности, а вблизи нее (в среднем на глубине 300 м) [*Иванюк и др.*, 2009].

Помимо Хибинского массива, в процессе обработки данных выделился комплекс кластеров, отражающих на полученной карте участок Ловозёрского щелочного массива [*Арзамасцев и др.*, 2013], который сложен субгоризонтальными чередующимися слоями нефелиновых сиенитов фойяит-малиньит-шонкинитового ряда и мельтейгит-уртитов. К северо-востоку от Ловозёрского эвдиалитового (*Zr-REE*) месторождения определен круг из кластеров в районе Кургинского щелочного массива. Графическое отображение результатов проведенного исследования на схемах нескольких видов (см. рис. 5)

демонстрирует явное наложение выделенных кластеров на рудные зоны Хибинского массива. При авторской итоговой обработке кластеров, полученных в результате анализа геофизических данных методом СОК, яркость их цвета меняется с глубиной залегания рудных зон – от близповерхностных апатитовых рудных зон с пологим падением 30–40° до прослеживаемых на глубину обнаружения геофизическими методами. С другой стороны, цветовое распределение выделенных кластерных групп может быть связано с морфологией рудных тел и переходом с глубиной более мощных линзовых месторождений в штокверковые.

Отсутствие цветового перехода от выделенных периферийных кластеров к кластерам, расположенным ближе к центру, может быть объяснено наличием разделяющего их высокогорного рельефа, не позволяющего геофизическими методами получить достаточные для обработки данные.

Заключение

Кластеризация данных – довольно быстрый и удобный способ их качественной интерпретации. С использованием представленного в работе метода самоорганизующихся карт Кохонена (СОК, метод нейронной сети без учителя) в автоматическом режиме без участия человека-интерпретатора вычислены кластеры, характеризующие рудные зоны Главного кольца Хибинского массива и подковообразной системы Ловозёрского плутона. Большинство кластеров выделенных цветов (см. рис. 5) соответствуют участкам развития рудной минерализации. К северо-востоку от названных структур по результатам обработки наметились два потенциальных участка, кластеры которых имеют схожие многомерные значения.

Авторами рекомендуется провести ревизию других площадей Кольского полуострова методом СОК с последующей аналогичной интерпретацией.

Конфликт интересов

Авторы заявляют об отсутствии конфликта интересов.

Литература

- Арзамасцев А.А., Арзамасцева Л.В., Жирова А.М., Глазнев В.Н. Модель формирования Хибинско-Ловозерского рудоносного вулcano-плутонического комплекса // Геология рудных месторождений. 2013. Т. 55, № 5. С.397–414.
- Иванюк Г.Ю., Горяинов П.М., Пахомовский Я.А., Коноплёва Н.Г., Яковенчук В.Н., Базай А.В., Калашиников А.О. Самоорганизация рудных комплексов. Синергетические принципы прогнозирования и поисков месторождений полезных ископаемых. М.: ГЕОКАРТ-ГЕОС, 2009. 392 с.
- Кириллов И.И., Морозов И.Н., Олейник А.Г. Разработка моделей экспресс-анализа обогащительных процессов на основе нейросетей и нечеткой логики // Труды Кольского научного центра РАН. 2013. № 5 (18). С.152–159.
- Кохонен Т. Самоорганизующиеся карты. Серия: Адаптивные и интеллектуальные системы. Пер. с англ. М.: Бином. Лаборатория знаний, 2008. 656 с.
- Никулин И.И., Савко А.Д. Железорудные коры выветривания Белгородского района Курской магнитной аномалии / Труды научно-исследовательского института геологии Воронежского государственного университета. Воронеж: Изд-во ВГУ, 2015. Вып. 85. 102 с.
- Самоорганизующиеся карты Кохонена – математический аппарат. URL: <https://basegroup.ru/community/articles/som> (дата обращения: 29.09.2020)

- Шаблинский Г.Н.* К вопросу о глубинном строении Хибинского и Ловозерского плутонов // Труды Ленинградского общества естествоиспытателей. 1963. Т. 74. С.41–43.
- Cavalcanti R.B.C., Pimentel B.A., de Almeida C.W.D., de Souza R.M.C.R.* A Multivariate Fuzzy Kohonen Clustering Network // 2019 International Joint Conference on Neural Networks (IJCNN). 2019. <https://ieeexplore.ieee.org/document/8852243>. doi: 10.1109/IJCNN.2019.8852243
- Diachenko V., Liashenko O., Ibrahim B.F., Mikhal O., Koltun Yu.* Kohonen Network with Parallel Training: Operation Structure and Algorithm // International Journal of Advanced Trends in Computer Science and Engineering. 2019. V. 8, N 1. P.35–38. doi.org/10.30534/ijatcse/2019/0681.22019
- Hu Z., Bodyanskiy Y.V., Tyshchenko O.K.* Kohonen Maps and Their Ensembles for Fuzzy Clustering Tasks // Self-Learning and Adaptive Algorithms for Business Applications, Emerald Publishing Limited, 2019. P.51–77. 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) // Scientific Reports. 2020. V. 10, N 17861. 13 p. <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, 2014. 336 p. doi.org/10.1002/9781118874059
- Samanta S., Utkarsha S., Gour B., Tiwari Kr.V.* Fast Character Recognition Using Kohonen Neural Network // 2018 International Conference on Advanced Computation and Telecommunication (ICACAT). 2018. <https://ieeexplore.ieee.org/document/8933627>. doi: 10.1109/ICACAT.2018.8933627
- Silva I.N., Spatti D.H., Flauzino R.A., Liboni L.H.B., dos Reis Alves S.F.* Self-Organizing Kohonen Networks // Artificial Neural Networks. Springer, Cham. 2017. P.157–172. 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 // 2019 IEEE/ACM International Conference on Advances in Social Networks Analysis and Mining (ASONAM). 2019. P.771–778. doi.org/10.1145/3341161.3344781

Сведения об авторах

НИКУЛИН Иван Иванович – доктор геолого-минералогических наук, заместитель директора по развитию геологоразведочных работ, ООО “Норильскгеология”. 195220, г. Санкт-Петербург, Гражданский проспект, д. 11. Тел.: +7(495) 787-76-67. E-mail: iinikulin@gmail.com

САМСОНОВ Алексей Андреевич – кандидат геолого-минералогических наук, ведущий инженер, Московский государственный университет имени М.В. Ломоносова. 119234, г. Москва, ул. Ленинские горы, д. 1. Тел.: +7 (495) 939-51-25. E-mail: 7400684@gmail.com

NEURAL NETWORK CLUSTER ANALYSIS OF AREAL GEOPHYSICAL DATA OF THE Khibiny-LOVOZERO VOLCANO-PLUTONIC ORE-BEARING COMPLEX (KOLA PENINSULA) BY SELF-ORGANIZING MAPS OF KOHONEN METHOD

I.I. Nikulin¹, A.A. Samsonov²

¹ LLC Norilskgeologiya, St. Petersburg, Russia

² Lomonosov Moscow State University, Moscow, Russia

Corresponding author: I.I. Nikulin (e-mail: iinikulin@gmail.com)

Abstract. The method of automatic express-interpretation of areal geophysical data is described using the example of the Khibiny-Lovozero volcano-plutonic complex. Within the framework of this method a complex geo-

physical-mathematical model was built, consisting of fifteen levels of hierarchy and based on the use of the mathematical apparatus of artificial neural networks. The method of self-organizing Kohonen maps was used in the processing of geophysical survey data. This is a mathematical apparatus of fuzzy logic, which artificial neural network is trained without a teacher. The formation of groups of clusters that characterize to the fullest extent the possible connections between multidimensional geophysical data is substantiated. As well as the presence of relationships between them is analyzed by identifying correlation dependences. The analysis of various geophysical transformants using self-organizing Kohonen maps is carried out. The clusters that as a result of the study reflect the picture of a major Paleozoic ore-magmatic system in the northeast of the Fennoscandian Shield were calculated using an artificial neural network. This system brings together the Khibiny and Lovozero plutons, Kurginskaya intrusion, volcanic formations and numerous swarms of alkaline dikes. A number of input indicators-representatives of their groups were determined and, on their basis, a geophysical-mathematical model in the form of a two-dimensional map of clusters using fuzzy logic tools was built. Terminological sets for each group of clusters were formed, the form of membership functions of previously unknown geological objects was specified according to the new interpreted data and their parameters in relation to the main ring of the Khibiny array, that controls rare-earth-titanium-aluminum-phosphorus deposits, and Fedoro-Panskaya Tundras (platinum-palladium deposits). Potential objects for geological exploration near the Lovozero eudialyte zircon rare-earth deposit are proposed. The conducted experimental study confirmed the adequacy of the constructed model and the effectiveness of its use for the purpose of express analysis of geophysical data and decision-making in geological prospecting tasks.

Keywords: gravity exploration, magnetic exploration, hierarchical model, artificial neural network, Kohonen map, fuzzy logic, cluster analysis

Conflict of interest

The authors declare they have no conflict of interest.

References

- Arzamastsev A.A., Arzamastseva L.V., Zhirova A.M., Glaznev V.N., Model of formation of the Khibiny-Lovozero ore-bearing volcanic-plutonic complex, *Geology of Ore Deposits*, 2013, vol. 55, no. 5, pp. 341-356.
- Cavalcanti R.B.C., Pimentel B.A., de Almeida C.W.D., de Souza R.M.C.R., A Multivariate Fuzzy Kohonen Clustering Network, *2019 International Joint Conference on Neural Networks (IJCNN)*, 2019, <https://ieeexplore.ieee.org/document/8852243>. doi: 10.1109/IJCNN.2019.8852243
- Diachenko V., Liashenko O., Ibrahim B.F., Mikhal O., Koltun Yu., Kohonen Network with Parallel Training: Operation Structure and Algorithm, *International Journal of Advanced Trends in Computer Science and Engineering*, 2019, vol. 8, no. 1, pp. 35-38. doi.org/10.30534/ijatcse/2019/0681.22019
- Hu Z., Bodyanskiy Y.V., Tyshchenko O.K., Kohonen Maps and Their Ensembles for Fuzzy Clustering Tasks, *Self-Learning and Adaptive Algorithms for Business Applications*, Emerald Publishing Limited, 2019, pp. 51-77, doi.org/10.1108/978-1-83867-171-620191004
- Ivanuk G.U., Gorayinov P.M., Pakhomovski Y.A., Konopleuva N.G., Yakovenchuk V.N., Bazai A.B., Kalashnikov A.O., *Samoorganizatsiya rudnykh kompleksov. Sinergeticheskie printsipy prognozirovaniya i poiskov mestorozhdenii poleznykh iskopaemykh* (Self-organization of ore complexes. Synergetic principles of forecasting and prospecting for mineral deposits), Moscow: GEOKART-GEOS, 2009, 392 p. [in Russian].
- 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, vol. 10, no. 17861, 13 p. <https://doi.org/10.1038/s41598-020-74505-y>
- Kirillov I.E., Morozov I.N., Oleynik A.G., Development of models based on neural networks and fuzzy logic for express analysis of ore-dressing processes, *Trudy Kolskogo nauchnogo centra RAN* (Proceedings of the Kola Scientific Center of the Russian Academy of Sciences), 2013, no. 5 (18), pp. 152-159. [in Russian].
- Kohonen T., *Samoorganizuyushchiesya karty. Seriya: Adaptivnye i intellektual'nye sistemy* (Self-organizing cards. Series: Adaptive and intelligent systems), Moscow: Binom. Laboratoriya znaniy, 2008, 656 p. [in Russian].
- Larose D.T., Larose C.D., *Discovering Knowledge in Data: An Introduction to Data Mining*, John Wiley & Sons, 2014, 336 p. doi.org/10.1002/9781118874059

- Nikulin I.I., Savko A.D., Iron ore weathering crust of the Belgorod region of the Kursk magnetic anomaly, *Trudy nauchno-issledovatel'skogo instituta geologii Voronezhskogo gosudarstvennogo universiteta* (Proceedings of the Research Institute of Geology, Voronezh State University), Voronezh: Voronezh State University, 2015, issue 85, 102 p. [in Russian].
- Samanta S., Utkarsha S., Gour B., Tiwari Kr.V., Fast Character Recognition Using Kohonen Neural Network, *2018 International Conference on Advanced Computation and Telecommunication (ICACAT)*, 2018. <https://ieeexplore.ieee.org/document/8933627>. doi: 10.1109/ICACAT.2018.8933627
- Samooorganizuuuzchiiesaya karty Kohonena – matematicheskii apparat (Kohonen's self-organizing maps – mathematical apparatus), URL: <https://basegroup.ru/community/articles/som>. Accessed 29.09.2020. [in Russian].
- Shablinsky G.N., To the question of the deep structure of the Khibiny and Lovozersky plutons, *Trudy Leningradskogo obshchestva estestvoispytatelei* (Proceedings of the Leningrad Society of Naturalists), 1963, vol. 74, pp. 41-43. [in Russian].
- Silva I.N., Spatti D.H., Flauzino R.A., Liboni L.H.B., dos Reis Alves F.S., Self-Organizing Kohonen Networks, *Artificial Neural Networks*, Springer, Cham, 2017, pp. 157-172. 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, *2019 IEEE/ACM International Conference on Advances in Social Networks Analysis and Mining (ASONAM)*, 2019, pp. 771-778. doi.org/10.1145/3341161.3344781

About the authors

NIKULIN Ivan Ivanovich – Dr. Sci. (Geol. and Mineral.), Deputy Director for development of geological exploration, Norilskgeologiya LLC, Grazhdanskiy prospect, 11, Saint-Petersburg, 195220, Russia. Ph.: +7(495) 787-76-67. E-mail: iinikulin@gmail.com

SAMSONOV Alexey Andreevich – Cand. Sci. (Geol. and Mineral.), Leading Engineer, Lomonosov Moscow State University, Leninskie Gory st., 1, Moscow, 119234, Russia. Ph.: +7(495) 939-51-25. E-mail: 7400684@gmail.com