

ИСПОЛЬЗОВАНИЕ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ГЕОМЕТРИЗАЦИИ СИЛЬВИНИТОВЫХ ПЛАСТОВ АБ И КР-2 НА ПРИМЕРЕ СКРУ-3 ОАО «УРАЛКАЛИЙ»

А.В. Катаев, Т.Ю. Чернавина

Пермский национальный исследовательский
политехнический университет, Пермь, Россия

Целью данной работы является получение наиболее достоверных и надежных результатов качественных свойств полезных ископаемых для 15-й панели СКРУ-3 ОАО «Уралкалий». Актуальность темы обоснована использованием высокопроизводительной добывающей техники в условиях недостаточности данных разведки о качестве полезного ископаемого на проектных участках. Исследования начинались с определения исходных данных и проведения пространственного анализа. Была проверена принадлежность имеющейся выборки данных к генеральной совокупности. Установлено, что данная выборка будет иметь те же свойства, что и генеральная совокупность.

Нейросетевой анализ выполнялся при помощи программы STATISTICA *Neural Network*. В процессе работы были получены лучшие варианты сетей, некоторые из них объединены в ансамбли для каждого из двух сильвинитовых пластов.

Контроль качества прогнозирования осуществлялся анализом остатков по сетям и ансамблям пластов АБ и Кр-2. С помощью гистограмм и графиков остатков было выдвинуто предположение, что плотность распределения остатков у сетей и сформированных ансамблей для обоих пластов успешно аппроксимируется нормальным законом распределения, что является признаком адекватности построения прогнозных моделей.

С использованием нейронных сетей выполнен прогноз на исследуемый участок. По результатам прогноза построены в изолиниях поверхности распределения содержания КСl (%) и остатков ансамбля. Причем построения выполнены с исключением значений наблюдений по 15-й панели для каждого из пластов. Исследованиями установлено наличие всплесков остатков по поверхности пластов, которые приурочены к зонам замещения. Анализ статистических параметров моделей и остатков подтвердил возможность и эффективность прогнозирования качественных свойств пластов на основе нейронных сетей.

Ключевые слова: нейронные сети, математическая статистика, геометризация месторождений, прогнозирование, анализ остатков, качественные свойства руды, ансамбль, нормальный закон распределения, коэффициент корреляции, выборка, генеральная совокупность, автокорреляция, зона замещения.

NEURAL NETWORK APPLICATIONS FOR GEOMETRIZATION OF SYLVINITE LAYERS AB AND KR-2 IN THE CASE OF SKRU-3 OJSC "URALKALI"

A.V. Kataev, T.Iu. Chernavina

Perm National Research Polytechnic University, Perm, Russian Federation

The aim of this work is to obtain the most accurate and reliable results of the qualitative properties of minerals for the 15th panel of SKRU-3 OJSC "Uralkali". Relevance of the topic is justified using high performance mining equipment in mining conditions of exploration data insufficient about the quality of mineral resource on project sites. Study began with determining the baseline data and spatial analysis. Belonging of the available sample database to the general population has been verified. Found that the sample had the same properties as the general population.

Neural network analysis was performed using the program STATISTICA *Neural Network*. During operation better networks options were obtained, some of them were combined in ensembles for each of the two sylvinitic layers.

Prediction quality control was performed by the residues analysis on networks and ensembles of layers AB and Kr-2. Using charts and graphs residues it has been suggested that the density distribution of the residuals from networks and generated ensembles for both layers is successfully approximated by the normal distribution, which is an indication of the adequacy of building predictive models.

With the use of neural networks a forecast for the sector was performed. According to the forecast surface of distribution content of KCl (%) and residues ensemble were constructed in isolines. Moreover constructing was performed with except for on the values of observations on the 15th panel for each of the layers. Studies have established the presence of residues bursts on the layers surface, which are confined to zones of substitution. Analysis of the statistical model parameters and residues confirmed the feasibility and effectiveness of qualitative properties of layers prediction based on neural networks.

Keywords: neural networks, mathematical statistics, geometrization of fields, forecasting, analysis of residues, qualitative properties of the oreensemble, normal distribution law, correlation coefficient, sample, population, autocorrelation, drive zone.

Под классической геометризацией месторождения полезных ископаемых понимают совокупность наблюдений, измерений, вычислительных и графических работ, имеющих целью получить геометрическое выражение форм, свойств полезных ископаемых, условий их залеганий и процессов, происходящих в недрах [1, 2]. При этом следует различать геометрию, присущую природным объектам, и геометризацию – как аппроксимацию и выражение этой геометрии с точностью, соответствующей данной стадии познания недр.

В данной работе ставится цель получить наиболее достоверные и надежные результаты качественных свойств полезных ископаемых на этапе планирования горных работ.

Современное горное производство характеризуется значительной сложностью горно-геологических условий разработки месторождений в связи с увеличением глубины разработки и вводом в эксплуатацию новых, как правило, более сложных по своему горно-геологическому строению участков залежей. В такой ситуации оперативный и точный прогноз горно-геологической обстановки, особенно при использовании высокопроизводительной добычной и проходческой техники, приобретает важное значение [3].

Для прогнозирования качественных показателей полезного ископаемого будут применены методы статистического анализа, а также использованы нейронные сети.

Нейронные сети – это раздел области исследования искусственного интеллекта, в котором для обработки сигналов используются явления, аналогичные происходящим в нейронах живых существ [4]. Этот инструмент используется везде, где требуется решать задачи прогнозирования, классификации или управления, поскольку они применимы практически в любой ситуации, когда имеется связь между переменными-предикторами (входными переменными) и прогнозируемыми переменными (выходными переменными).

Технология сетей используется, даже если эта связь имеет сложную природу и ее трудно выразить в обычных терминах корреляции или различий между группами [5]. Методы нейронных сетей могут использоваться независимо или служить дополнением к традиционным методам анализа.

Большинство статистических методов связано с построением моделей, основанных на тех или иных предположениях и теоретических выводах. Нейросетевой подход свободен от модельных ограничений, он одинаково применим для линейных и сложных нелинейных зависимостей и особенно эффективен в разведочном анализе данных, когда необходимо выяснить, имеется ли вообще зависимость между переменными. Сила нейронных сетей заключается в их способности самообучаться. Процедура обучения состоит в настройке синоптических весов с целью минимизации функции потерь.

Для выполнения анализа воспользуемся программным пакетом STATISTICA, разработанным фирмой StatSoft Inc. (США) [6]. Поскольку инженерные службы рудников ОАО «Уралкалий» для ведения маркшейдерских планов горных работ используют ГИС MapInfo, графическая часть работы будет также представлена в этой системе.

Исходными данными для выполнения статистического анализа является совмещенный план горных выработок, разведочных выработок и земной поверхности на исследуемом участке рудника СКРУ-3. Использовались также результаты исследований по подземным, глубоким скважинам и пробам.

Прогнозирование качественных свойств на 15-ю юго-восточную панель выполним, используя данные проб и скважин, расположенных на рабочих панелях № 1, № 2, № 3, № 4, № 5, № 6, № 8, № 15, № 17, № 18 для каждого из продуктивных сильвинитовых пластов АБ и Кр-2.

После предварительного анализа и обработки данных для пласта АБ количество

проб и скважин составило 688, а для пласта Кр-2 – 665.

Пробы, отобранные с определенной плотностью по всей площади пласта, представляют генеральную совокупность [7]. При больших объемах генеральной совокупности объекты изучают путем извлечения из нее части показателей, называемой выборочной совокупностью, или выборкой. Причем объем N генеральной совокупности во много раз превышает объем выборки n . Для того чтобы по выборке можно было достаточно точно судить о случайной величине [8–10], выборка должна быть представительной (репрезентативной) – это означает, что объекты выборки достаточно хорошо представляют генеральную совокупность. Исследуемые пробы и скважины пластов АБ и Кр-2 – это выборка, и она принадлежит некой генеральной совокупности.

Исходные данные по каждому пласту образуют некоторое компактное облако, принадлежат некоторой генеральной совокупности данных. В результате анализа первичных статистик установлено, что они имеют те же свойства, что и генеральная совокупность.

Пространственно-статистический анализ пласта Кр-2 дал аналогичные результаты.

Данные для анализа находятся на разных слоях геоинформационной системы. Результаты наблюдений этих слоев сведены в одну таблицу в приложении Microsoft Excel для каждого изучаемого силвинитового пласта АБ и Кр-2. Структуры таблиц данных включали

координаты скважин – X , м; мощность полезного ископаемого – M , м; содержание полезных и вредных веществ, код наблюдения. Переменная Code задавалась для обозначения кода выборки, она может принимать следующие значения:

1 – соответствует обучающим наблюдениям;

2 – соответствует тестовым наблюдениям;

3 – соответствуют контрольным наблюдениям;

5 – игнорируемые данные, принадлежащие исследуемой 15-й панели.

Данные из Microsoft Excel экспортировались в приложение STATISTICA, где и производилась дальнейшая обработка данных. Анализ выполнялся в нейронных сетях, глубина анализа задавалась числом испытываемых сетей. Количество сетей выбиралось от 100 до 5000. Теоретическая составляющая нейронных сетей приводится в литературе [11] и в настоящей статье не излагается. В качестве типа сети выбирались обобщенная регрессионная нейронная сеть, радиальная базисная функция, многослойный перцептрон, линейная функция.

По пласту АБ прогнозировалось содержание полезного компонента KCl, остальные переменные были входными. В качестве кода выборки выбиралась переменная – Code. В процессе построения сетей игнорировались все данные, принадлежащие проектной панели (имеющие код, равный 5).

После запуска пакета STATISTICA *Neural Networks* происходило обучение и проверка сетей. После окончания расче-

Таблица 1

Описательные статистики лучших сетей пласта АБ

Параметр	KCL.41	KCL.72	KCL.74	KCL.76	KCL.80
Среднее данных	31,87	31,87	31,87	31,87	31,87
Среднее отклонение данных	5,29	5,29	5,29	5,29	5,29
Среднее ошибки	0,01	0,05	-0,05	0,03	-0,04
Стандартное отклонение данных	4,53	4,28	4,27	4,24	4,28
Среднее абсолютной ошибки	3,36	3,12	3,12	3,07	3,17
Отношение стандартного отклонения	0,86	0,81	0,81	0,80	0,81
Корреляция	0,55	0,59	0,59	0,60	0,59

Таблица 2

Подробные результаты моделей пласта АБ

Параметр	Архитектура	Производная обучения	Контрольная производная	Тестовая производная	Ошибка обучения	Контрольная ошибка	Тестовая ошибка	Обучение/элементы
KCL.41	РБФ	0,753	0,892	0,928	0,131	0,142	0,142	КС, КБ, ПО
KCL.72	МП	0,840	0,763	0,836	0,110	0,099	0,115	ОР100, СГ20, СГ3б
KCL.74	МП	0,787	0,833	0,817	0,104	0,099	0,104	ОР100, СГ20, СГ12б
KCL.76	МП	0,833	0,757	0,808	0,114	0,099	0,102	ОР100, СГ20, СГ3б
KCL.80	МП	0,833	0,759	0,828	0,113	0,098	0,114	ОР100, СГ20, СГ6б

тов программа выводит лучшие сети, по которым можно просмотреть и проанализировать полученные результаты.

Из полученных результатов были выбраны некоторые из тех сетей, которые имели лучшие оценки на обучающей, проверочной и тестовой последовательностях. Конечным критерием отбора был коэффициент корреляции. Сети по пласту АБ с наиболее высоким коэффициентом корреляции представлены в табл. 1. Подробные результаты по сетям представлены в табл. 2. Коэффициенты корреляции получились невысокими. Но следует отметить, что сети обучены на одной части данных и проверены на другой части, поэтому степень доверия к сетям высокая. Лучшие сети получились разных типов: KCL.41 – сеть получена на основе радиальной базисной функции; сети KCL.72, KCL.74, KCL.76, KCL.80 – с использованием многослойного персептрона.

Среднее значение ошибки в полученных сетях близко к нулю. В статьях, посвященных нейронным сетям, отмечается возможность формирования ансамблей, включающих несколько сетей. При корректном объединении сетей прогностическое качество ансамбля улучшается.

По лучшим сетям был создан ансамбль, описательные статистики которого представлены в табл. 3.

Коэффициент корреляции у полученного ансамбля выше, чем у составляющих его сетей. Средняя величина ошибки (остатка) равна нулю. Подробные результаты модели ансамбля представлены в табл. 4.

По пласту Кр-2 сеть создавалась аналогично пласту АБ: содержание KCL (%) – выходная переменная; X (м), Y (м), M (м), НО (%), MgCl (%) – входные переменные.

Лучшие сети пласта Кр-2 представлены в табл. 5. Подробные результаты по сетям представлены в табл. 6. Тип лучших сетей – многослойный персептрон. Значение коэффициента корреляции – 0,62. Средние ошибки в полученных сетях близки к нулю.

Описательные статистики [12] ансамбля по лучшим сетям представлены в табл. 7.

Таблица 3

Описательные статистики ансамбля по пласту АБ

Параметр	Ансамбль
Среднее данных	31,87
Среднее отклонение данных	5,29
Среднее ошибки	0,00
Стандартное отклонение данных	4,19
Среднее абсолютной ошибки	3,05
Отношение стандартного отклонения	0,79
Корреляция	0,61

Таблица 4

Подробные результаты модели ансамбля по пласту АБ

Архитектура	Производная обучения	Контрольная производная	Тестовая производная	Ошибка обучения	Контрольная ошибка	Тестовая ошибка	Обучение/элементы
Выход 5: [5]: 1	0,809	0,801	0,843	0,114	0,107	0,115	41 72 74 76 80

Таблица 5

Описательные статистики лучших сетей пласта Кр-2

Параметр	KCL.73	KCL.94	KCL.82	KCL.62	KCL.101
Среднее данных	24,053	24,053	24,05279	24,053	24,053
Среднее отклонение данных	3,953	3,953	3,95292	3,953	3,953
Среднее ошибки	-0,293	0,094	0,08752	-0,058	0,170
Стандартное отклонение данных	3,156	3,253	3,23039	3,408	3,339
Среднее абсолютной ошибки	2,405	2,416	2,41965	2,479	2,386
Отношение стандартного отклонения	0,798	0,823	0,81722	0,862	0,845
Корреляция	0,612	0,569	0,57659	0,507	0,537

Таблица 6

Подробные результаты моделей пласта Кр-2

Параметр	Архитектура	Производная обучения	Контрольная производная	Тестовая производная	Ошибка обучения	Контрольная ошибка	Тестовая ошибка	Обучение/элементы
KCL.62	МП	0,873	0,954	0,930	0,111	0,089	0,118	OP100, CG20, CG21b
KCL.73	МП	0,725	0,826	1,047	0,089	0,086	0,081	OP100, CG20, CG45b
KCL.82	МП	0,796	0,869	0,973	0,093	0,083	0,079	OP100, CG20, CG15b
KCL.94	МП	0,703	0,943	0,912	0,084	0,080	0,116	OP100, CG20, CG55b
KCL.101	МП	0,715	0,905	0,928	0,076	0,077	0,130	OP100, CG20, CG18b

Таблица 7

Описательные статистики ансамбля пласта Кр-2

Параметр	Ансамбль
Среднее данных	24,053
Среднее отклонение данных	3,953
Среднее ошибки	-0,000
Стандартное отклонение данных	3,165
Среднее абсолютной ошибки	2,369
Отношение стандартного отклонения	0,801
Корреляция	0,603

Значение коэффициента корреляции у полученного ансамбля ниже, чем у лучшей сети, но выше, чем у всех остальных составляющих его сетей. Среднее ошибки близко к нулю. Подробные результаты модели ансамбля приведены в табл. 8.

Архитектура лучших нейронных сетей пластов АБ и Кр-2 представлена на рис. 1.

Таблица 8

Подробные результаты модели ансамбля пласта Кр-2

Архитектура	Производная обучения	Контрольная производная	Тестовая производная	Ошибка обучения	Контрольная ошибка	Тестовая ошибка	Обучение/элементы
Выход 5: [5]: 1	0,756	0,888	0,948	0,085	0,083	0,105	62 73 82 94 101

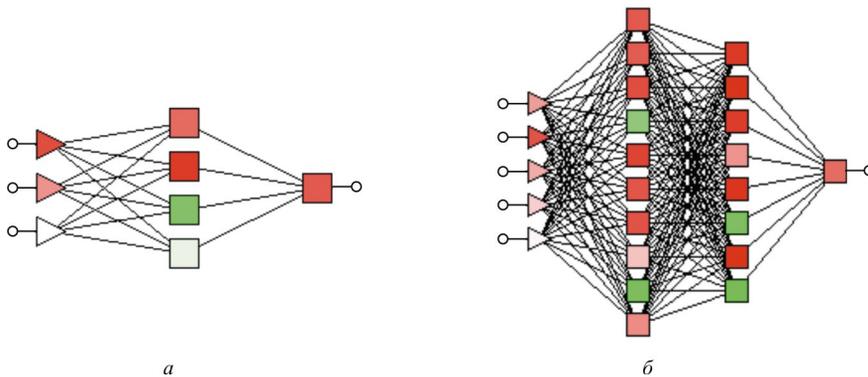


Рис. 1. Архитектуры сети KCL.76 пласта АБ (а) и сети KCL.73 пласта Кр2 (б)

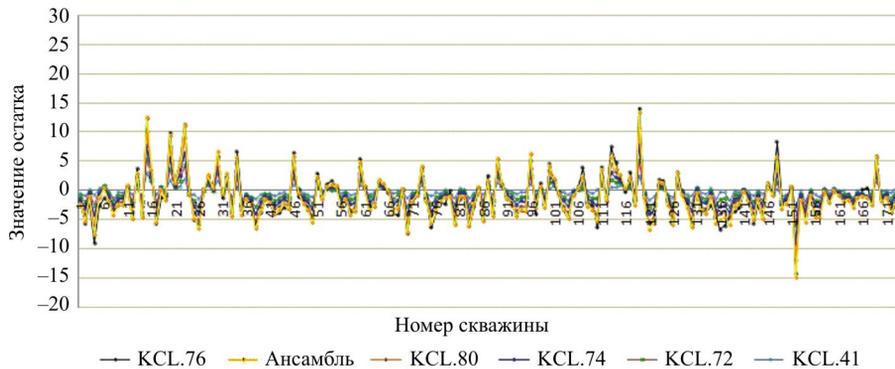


Рис. 2. Фрагмент графика остатков сетей и ансамбля пласта АБ

По лучшим сетям и ансамблям сильвинитовых пластов были получены остатки, для которых произведен анализ и прогноз.

В статистических исследованиях линейная регрессионная модель считается адекватной, если вычисленные по ней значения функции согласуются с результатами наблюдений, а остатки подчиняются нормальному закону распределения со средним значением, близким к нулю, и не имеют автокорреляции. Аналогичный вывод можно принять и по нейронным сетям. О нормальности остатков сетей пласта АБ можно судить по графику остатков (рис. 2).

Остатки должны быть нормально распределены, т.е. на графике они должны представлять приблизительно горизонтальную полосу одинаковой ширины на всем ее протяжении. Разброс остатков по сетям выше, чем по ансамблю, ансамбль сглаживает экстремальные всплески остатков сетей.

Предположение о нормальности остатков проверено с помощью гистограмм остатков сетей и ансамблей. Наиболее представительная гистограмма остатков по пласту АБ представлена на рис. 3.

Из анализа всех гистограмм можно предположить, что плотность распределения остатков у сетей и сформированного ансамбля успешно аппроксимируется нормальным законом распределения, что является признаком адекватности построения

прогноза модели. На гистограмме наблюдается незначительная асимметрия.

О нормальности остатков сетей и составленному по ним ансамблю пласта Кр-2 можно судить по графику остатков, фрагмент которого приведен на рис. 4.

Остатки на графике представляют приблизительно горизонтальную полосу одинаковой ширины на всем ее протяжении, но привлекают внимание отдельные точки – «выбросы». Данные значения являются некорректными. Их можно проверить на наличие грубых ошибок и впоследствии исключить из рассмотрения. Но также необходимо определить их местоположение на плане, проверить наличие каких-либо замещений, нарушений или иных зон, к которым они могут быть приурочены. Примечательно, что разброс остатков по сетям пласта Кр-2 так же, как и на пласте АБ, выше, чем по ансамблю.

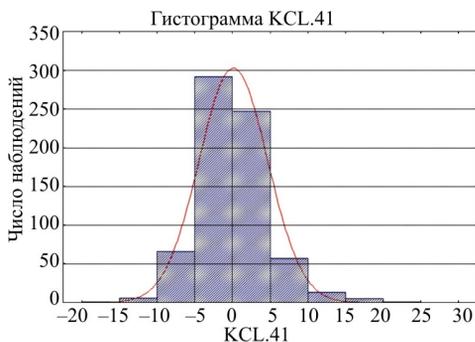


Рис. 3. Гистограмма остатков нейронной сети KCL.41

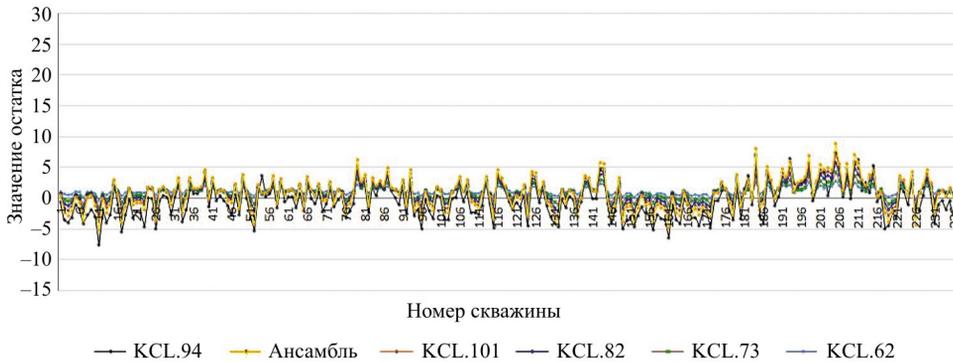


Рис. 4. Фрагмент графика остатков сетей и ансамбля пласта Кр-2

Предположение о нормальности остатков по пласту Кр-2 также проверено с помощью гистограмм остатков. Наиболее представительная гистограмма остатков по пласту Кр-2 приведена на рис. 5.

Из анализа построенных гистограмм можно предположить, что выборочная плотность распределения остатков у сетей и сформированного ансамбля успешно аппроксимируется нормальным законом распределения, что является признаком, подтверждающим адекватность построенной модели прогноза.

Для прогнозирования качества на 15-ю панель был выделен исследуемый участок по пласту АБ. Прогноз производился графическим способом.

В программном пакете MapInfo Professional была построена поверхность изолиний по фактическому содержанию КС1 (рис. 6). По остаткам полученного ансамбля пласта АБ была построена поверхность изолиний (рис. 7).

Полученный ансамбль по лучшим нейронным сетям был пересчитан в пакете STATISTICA Neural Networks, с включением во входные данные проб с 15-й панели (с кодом 5).

Остатки по пересчитанному ансамблю имеют следующие описательные статистики, представленные в табл. 9.

По остаткам нового ансамбля построена поверхность изолиний (рис. 8). На карте изолиний видно, что большие по абсолютной величине остатки ансамбля попадают в зону замещения.

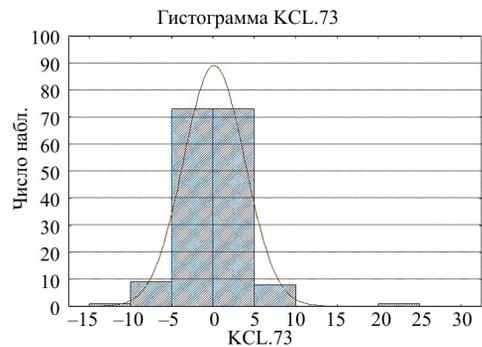


Рис. 5. Гистограмма остатков нейронной сети KCL.73

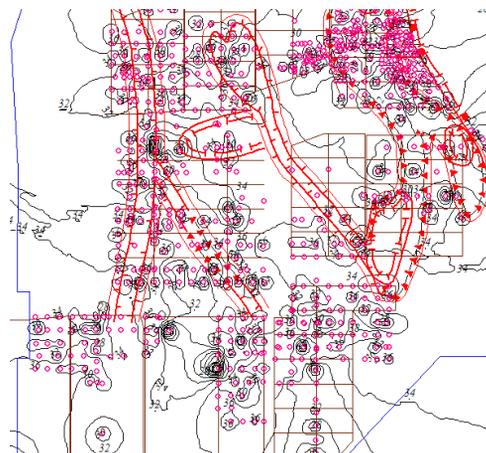


Рис. 6. Изолинии распространения содержания КС1, %, пласта АБ, масштаб 1:50000:

- – скважина; — граница горного отвода;
- границы панелей; — зона замещения

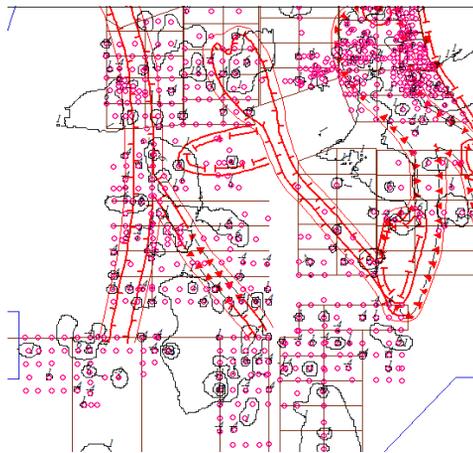


Рис. 7. Карта изолиний по остаткам ансамбля пласта АБ, масштаб 1:50000:

○ – скважина; — (синяя) – граница горного отвода;
— (черная) – границы панелей; — (красная) – зона замещения

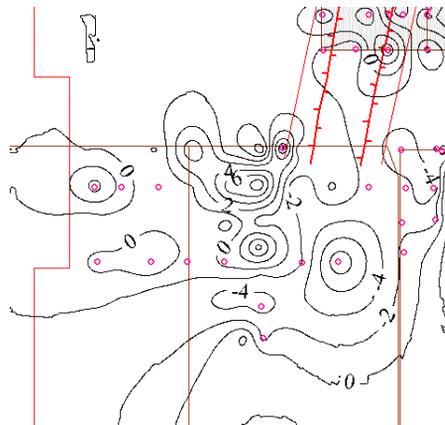


Рис. 8. Карта изолиний по остаткам ансамбля на исследуемой 15-й панели пласта АБ, масштаб 1:2000: ○ – скважина; — (синяя) – граница горного отвода; — (черная) – границы панелей; — (красная) – зона замещения

Таблица 9

Описательные статистики по остаткам ансамбля, с включением в обучение данных 15-й панели

Параметр	Значение
Среднее значение	0,00019
Медиана	-0,581
Стандартное отклонение	4,192
Количество наблюдений	688
Сумма наблюдений	0,131
Минимальное наблюдение	-14,815
Максимальное наблюдение	24,492

Поскольку в обучение сетей были включены наблюдения со значением 5, принадлежащие 15-й панели, можно сделать прогноз размещения зоны замещения на исследуемый участок. Зона замещения (сильвинит – карналлит) для пласта АБ будет проходить по восточному крылу 15-й панели.

Для прогноза пространственным анализом был выделен исследуемый участок по пласту Кр-2. В программном пакете MapInfo Professional построена поверхность изолиний по фактическому содержанию КС1 (рис. 9). Также по остаткам полученного ансамбля Кр-2 построена поверхность изолиний (рис. 10).

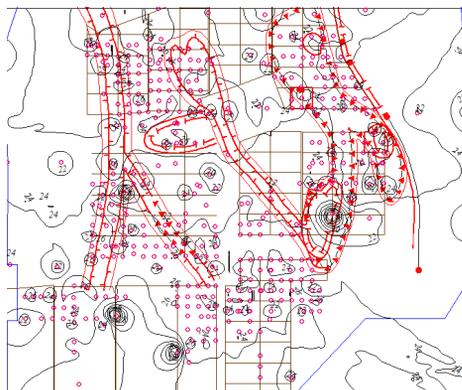


Рис. 9. Карта изолиний по содержанию КС1, % пласта Кр-2, масштаб 1:50000:

○ – скважина; — (синяя) – граница горного отвода; — (черная) – границы панелей; — (красная) – зона замещения

Распределение остатков в пределах пласта имеет случайный характер, о чем свидетельствует наличие мелкосопочного рельефа. Его формируют почти последовательное чередование положительных и отрицательных форм, образованных остатками.

Полученный ансамбль по лучшим нейронным сетям был пересчитан в пакете STATISTICA Neural Networks, с включением во входные данные значения наблюдений

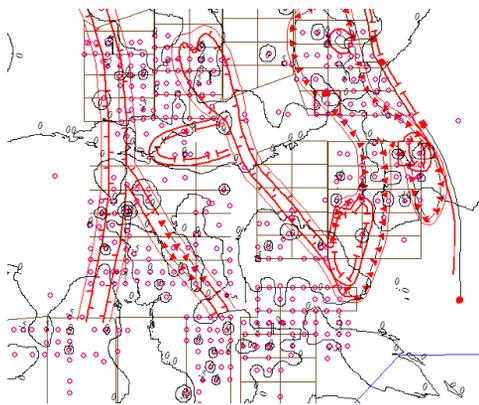


Рис. 10. Карта изолиний по остаткам ансамбля пласта Кр-2, масштаб 1:50000:

○ – скважина; — (синяя) – граница горного отвода;
— (коричневая) – границы панелей; — (черная) – очистные и подготовительные камеры;
— (красная) – зона замещения



Рис. 11. Карта изолиний по остаткам нового ансамбля пласта Кр-2, масштаб 1:2000:

○ – скважина; — (синяя) – граница горного отвода;
— (черная) – границы панелей; — (красная) – зона замещения

дений с кодом 5. По остаткам нового ансамбля построена поверхность изолиний (рис. 11).

Остатки по пересчитанному ансамблю имеют описательные статистики, представленные в табл. 10.

Так же как и на пласте АБ, на карте изолиний всплески остатков ансамбля попадают в зону замещения. Анализ данных по пласту Кр-2 подтверждает, что зона замещения (сильвинит – каменная соль) будет проходить по восточному крылу 15-й панели.

Таким образом, использование в процессе проведенных исследований различных методов и инструментов прикладной и математической статистики позволило решить поставленную задачу. В результате исследований установлена принадлежность имеющейся выборки данных генеральной совокупности. При помощи пространственно-статистического анализа было установлено, что данная выборка является представительной и имеет те же свойства, что и генеральная совокупность.

В приложении STATISTICA *Neural Networks* были выполнены расчеты и полу-

Таблица 10

Описательные статистики по остаткам ансамбля с включением в обучение данных 15-й панели

Параметр	Значение
Среднее значение	-0,000066
Медиана	-0,099
Стандартное отклонение	3,169
Количество наблюдений	405
Сумма наблюдений	-0,027
Минимальное наблюдение	-10,423
Максимальное наблюдение	24,677

чены лучшие варианты сетей по каждому пласту. Сети объединены в ансамбли для каждого из сильвинитовых пластов.

На следующем этапе работы был проведен анализ остатков. По гистограммам остатков можно предположить, что выборочная плотность распределения остатков у сетей и сформированных ансамблей для обоих пластов успешно аппроксимируется нормальным законом распределения, что является признаком адекватности построения прогнозных моделей. Разброс остатков полученных ансамблей ниже, чем по отдельным сетям, что подтверждает необходимость группировки сетей в ансамбль. При этом уменьшается и сумма остатков.

Построенные ансамбли позволили заполнить прогноз на исследуемый участок. Были получены планы изолиний по содержанию КСl, %, по остаткам ансамбля с исключением значений наблюдений 15-й панели и включением для обоих пла-

стов. Анализ результатов прогнозирования показал, большие по абсолютной величине остатки попадают в зону замещения, которая по результатам прогноза должна проходить по восточному крылу 15-й панели для обоих пластов.

Список литературы

1. Букринский В.А. Геометрия недр. – М.: Изд-во Моск. гос. гор. ун-та, 2002. – 549 с.
2. Геометрия недр (горная геометрия) / В.М. Калинин, Н.И. Степин, И.П. Турикин, И.Н. Ушаков; под ред. В.М. Калинин, И.Н. Ушакова. – Новочеркасск, 2000. – 526 с.
3. Калинин В.М. Математическое моделирование и прогноз показателей месторождений. – М.: Недра, 1993. – 319 с.
4. Осовский С. Нейронные сети для обработки информации / пер. с пол. И.Д. Рудинского. – М.: Финансы и статистика, 2004. – 344 с.
5. Боровиков В.П. Нейронные сети. STATISTICA Neural Networks: Методология и технология современного анализа данных. – М.: Горячая линия – Телеком, 2008. – 392 с.
6. Боровиков В.П., Боровиков И.П. STATISTICA. Статистический анализ и обработка данных в среде WINDOWS. – М.: Филинь, 1997. – 600 с.
7. Катаев А.В., Кутовой С.Н., Ашихмин С.Г. Математическая статистика в горном деле: учеб.-метод. пособие. – Пермь: Изд-во Перм. гос. техн. ун-та, 2009. – 98 с.
8. Рыжов П.А. Математическая статистика в горном деле. – М.: Высшая школа, 1973. – 287 с.
9. Горное дело: терминологический словарь / Г.Д. Лидин, Л.Д. Воронина, Д.Р. Каплунов [и др.]. – М.: Недра, 1990. – 694 с.
10. Шагагин Н.И., Щеглов В.И. Моделирование месторождений и рудных полей на ЭВМ (диалоговые системы). – М.: Недра, 1989.
11. Татузов А.Л. Нейронные сети в задачах радиолокации. – М.: Радиотехника, 2009. – 432 с.
12. Девис Дж. Статистика и анализ геологических данных / пер. с англ. В.А. Голубева; под ред. Д.А. Родионова. – М.: Мир, 1977. – 572 с.
13. Automation of research data process and shift/deformation for easting of under mined ground on potassium salt mines of the verchnekamskiy deposit / S. Kutovoy, A. Kataev, P. Krasnoschekov, P. Shamin // Proceedings of the international geomechanics conference theory and practice of geomechanics for effectiveness the mining production and the construction. – Bulgaria: Scientific and technical union of mining, geology and metallurgy, 2010. – 371 p.
14. Ивановна В., Топалов С. Прогнозирование на геотехнических показатели через многофакторный регрессионный анализ // Proceedings of the international geomechanics conference theory and practice of geomechanics for effectiveness the mining production and the construction. – Bulgaria: Scientific and technical union of mining, geology and metallurgy, 2010. – 99 p.
15. JSC “Silvinit” Information Systems Development. Разработка концепции информационной системы ОАО «Сильвинит» / А.В. Катаев, С.Н. Кутовой, Е.В. Нестеров, М.В. Гилев // XIII Международный Конгресс по маркшейдерскому делу, доклад № 123. – Будапешт, Венгрия, 2007. – 5 с.

References

1. Bukrinskii V.A. Geometriia neдр [Geometry of bowels]. Moscow: Izdatel'stvo Moskovskogo gosudarstvennogo gornogo universiteta, 2002. 549 p.
2. Kalinchenko V.M., Stepin N.I., Turikin I.P., Ushakov I.N. Geometriia neдр (gornaiа geometriia) [Geometry of bowels (mountains geometry)]. Novocherkassk, 2000. 526 p.
3. Kalinchenko V.M. Matematicheskoe modelirovanie i prognoz pokazatelei mestorozhdenii [Mathematical modeling and forecast of indicators fields]. Moscow: Nedra, 1993. 319 p.
4. Osovskii S. Neironnye seti dlia obrabotki informatsii [Neural Networks for processing the information]. Moscow: Finansy i statistika, 2004. 344 p.
5. Borovikov V.P. Neironnye seti. STATISTICA Neural Networks: Metodologiya i tekhnologiya sovremennogo analiza dannykh [Neural networks. STATISTICA Neural Networks: Methodology and technology of modern data analysis]. Moscow: Goriachaia liniia – Telekom, 2008. 392 p.
6. Borovikov V.P., Borovikov I.P. STATISTICA. Statisticheskii analiz i obrabotka dannykh v srede WINDOWS [STATISTICA. Statistical analysis and data processing in the WINDOWS environment]. Moscow: Filin", 1997. 600 p.

7. Kataev A.V., Kutovoi S.N., Ashikhmin S.G. Matematicheskaya statistika v gornom dele: uchebnoe metodicheskoe posobie [Mathematical Statistics in mining: teaching and methodical manual]. Perm: Izdatel'stvo Permskogo gosudarstvennogo tekhnicheskogo universiteta, 2009. 98 p.

8. Ryzhov P.A. Matematicheskaya statistika v gornom dele [Mathematical Statistics in mining]. Moscow: Vysshaya shkola, 1973. 287 p.

9. Lidin G.D., Voronina L.D., Kaplunov D.R., Bronnikov D.M. Gornoe delo: terminologicheskii slovar' [Mining: terminological dictionary]. Moscow: Nedra, 1990. 694 p.

10. Shtagin N.I., Shcheglov V.I. Modelirovanie mestorozhdenii i rudnykh polei na EVM (dialogovye sistemy) [Simulation of deposits and ore fields on a computer (interactive systems)]. Moscow: Nedra, 1989. 150 p.

11. Tuzov A.L. Neironnye seti v zadachakh radiolokatsii [Neural networks in tasks radar]. Moscow: Radiotekhnika, 2009. 432 p.

12. Devis Dzh. Statistika i analiz geologicheskikh dannykh [Statistics and analysis of geologic the data]. Moscow: Mir, 1977. 572 p.

13. Kutovoy S., Kataev A., Krasnoschekov P., Shamin P. Automation of research data process and shift/deformation for easting of under mined ground on potassium salt mines of the verchnekamskiy deposit. *Proceedings of the international geomechanics conference theory and practice of geomechanics for effectiveness the mining production and the construction*. Bulgaria: Scientific and technical union of mining, geology and metallurgy, 2010. 371 p.

14. Ivanova V., Topalov S. Proceedings of the international geomechanics conference theory and practice of geomechanics for effectiveness the mining production and the construction. Bulgaria: Scientific and technical union of mining, geology and metallurgy, 2010. 99 p.

15. Kataev A.V., Kutovoi S.N., Nesterov E.V., Gilev M.V. Razrabotka kontseptsii informatsionnoi sistemy OAO "Sil'vinit" [Development of the concept of information system JSC "Silvinit"]. *XIII Mezhdunarodnyi Kongress po marksheiderskomu delu*. Budapesht, Vengriia, 2007, 5 p.

Об авторах

Катаев Анатолий Вениаминович (Пермь, Россия) – кандидат технических наук, доцент кафедры маркшейдерского дела, геодезии, геоинформационных систем Пермского национального исследовательского политехнического университета (614990, г. Пермь, Комсомольский пр., 29; e-mail: geotech@pstu.ac.ru).

Чернавина Татьяна Юрьевна (Пермь, Россия) – Пермский национальный исследовательский политехнический университет (614990, г. Пермь, Комсомольский пр., 29; e-mail: geotech@pstu.ac.ru).

About the authors

Anatolii V. Kataev (Perm, Russian Federation) – Ph.D. in Technical Sciences, Associate Professor, Department of Mine Surveying, Geodesy and Geoinformation Systems, Perm National Research Polytechnic University (614990, Perm, Komsomolsky av., 29; e-mail: geotech@pstu.ac.ru).

Tat'iana Iu. Chernavina (Perm, Russian Federation) – Perm National Research Polytechnic University (614990, Perm, Komsomolsky av., 29; e-mail: geotech@pstu.ac.ru).

Получено 28.08.2013