

ОБРАБОТКА СТРУКТУРНЫХ ГЕОЛОГИЧЕСКИХ МОДЕЛЕЙ АЛГОРИТМАМИ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

М.П. Сергунин¹, В.А. Еременко²

¹ Заполярный филиал ПАО «ГМК «Норильский никель», Норильск, Россия

² Горный институт НИТУ «МИСиС», Москва, Россия, e-mail: prof.eremenko@gmail.com

Аннотация: Представлен пример обучения нейронной сети, способной обрабатывать и классифицировать триангуляционные каркасы структурных геологических моделей. Классификация каркасов осуществляется на основании собственных расчетных значений векторов литологических поверхностей. Точность модели составила 98,2%, что подтверждает возможность использования алгоритма машинного обучения для классификации и выделения объектов, позволяет увеличить скорость обработки данных и снизить вероятность ошибок, обусловленных влиянием человеческого фактора. После выделения каркасов тектонических нарушений и литологических контактов из структурных геологических моделей по каждому каркасу определяется дополнительная информация о положении в пространстве (средний угол падения, азимут падения) и характеристиках поверхности, таких как неровность и волнистость, что позволяет использовать полученные данные для выполнения кинематического анализа и решения задач сдвижений горных пород. В качестве исходных данных в обучаемой модели используются коэффициенты Вудкока и собственные расчетные значения векторов. Данные характеристики могут применяться для уточненной оценки состояния блочного массива и для определения степени сцепления тектонических нарушений, что позволяет повысить точность прогнозных моделей, и в дальнейшем использоваться для обучения моделей, описывающих параметры сдвижения налегающей толщи горных пород.

Ключевые слова: тектонические нарушения, обработка литолого-структурных моделей, кинематический анализ, нейронная сеть, диаграмма поверхности, метод собственных значений векторов, параметры Вудкока, сдвижение горных пород.

Для цитирования: Сергунин М. П., Еременко В. А. Обработка структурных геологических моделей алгоритмами искусственного интеллекта // Горный информационно-аналитический бюллетень. – 2023. – № 9. – С. 2–13. DOI: 10.25018/0236_1493_2023_9_0_2.

Application of artificial intelligence algorithm in processing structural geological models

M.P. Sergunin¹, V.A. Eremenko²

¹ Polar Division of MMC Norilsk Nickel, Norilsk, Russia

² Mining Institute, National University of Science and Technology «MISIS», Moscow, Russia,
e-mail: prof.eremenko@gmail.com

Abstract: An example of learning a neural network capable of processing and classifying triangulation frameworks of structural geological models is presented. The classification of the

frameworks uses the proper calculated vectors of lithological surfaces. The accuracy of the models is 98.2%, which confirms the usability of the machine learning algorithm in classifying and selecting objects at the increased speed of data processing and at the reduced likelihood of errors due to the human factor. After separating the frameworks of tectonic faults and lithological contacts from structural geological models, an additional information on spatial position (average dip angle, dip azimuth) and surface characteristics, such as roughness and waviness, is determined for each framework, which allows using the obtained data to perform kinematic analyses and for solving problems connected with rock movements. The Woodcock coefficients and the eigenvalues of the vectors are used as input data in the model being trained. These characteristics can be used for a refined assessment of the state of a block massif and used to determine the degree of adhesion of tectonic faults, which makes it possible to improve the accuracy of predictive models and subsequently be used to train models that describe the parameters of displacement of the overlying rock mass.

Key words: faulting, geological model, kinematic analysis, neural network, specification of fabric shapes, eigenvector methods, Woodcock's fabric parameters, rock movements.

For citation: Sergunin M. P., Eremenko V. A. Application of artificial intelligence algorithm in processing structural geological models. *MIAB. Mining Inf. Anal. Bull.* 2023;(9):2-13. [In Russ]. DOI: 10.25018/0236_1493_2023_9_0_2.

Введение

Сбор и обработка данных в геомеханике является трудоемкой задачей, а их качество и объем имеют определяющее значение при выборе технических решений. В настоящее время наибольшее распространение получили численные методы, которые хорошо себя зарекомендовали и имеют наглядную визуализацию. При всех достоинствах основным недостатком, ограничивающим применение этих методов, является их трудоемкость и высокие квалификационные требования, предъявляемые к компетентности специалистов. В современных условиях развития горнодобывающей отрасли растет роль показателей, влияющих на скорость принятия решения, эти тенденции уже затронули практически все сферы деятельности и проникают в прикладные области в виде систем искусственного интеллекта. К сожалению, численные методы решений чувствительны к геометрии моделей, поэтому на предварительном этапе большая часть време-

ни уходит на исправление ошибок геометрии моделей и их предварительную подготовку. Следующим негативным фактором являются высокие требования к вычислительным ресурсам. Например, простые локальные модели с линейными свойствами материалов достаточно быстро сходятся и требуют минимальных временных затрат, однако при рассмотрении региональных моделей, обладающих анизотропными свойствами и имитирующих несколько шагов нагружения, сходимость решений обеспечивается за счет применения многократных итераций, в результате чего происходит снижение скорости, а само решение без учета построения и настройки модели существенно затягивается во времени. В этих условиях важным направлением развития искусственного интеллекта в геомеханике является поиск и развитие методов, обладающих минимальными требованиями к вычислительным ресурсам и требующих, по возможности, минимального участия человека при под-




Рис. 1. Пример литолого-структурной модели
Fig. 1. An example of a lithological-structural model

готовке и обработке данных.

В геомеханике перспективным направлением применения методов машинного обучения являются задачи построения и обработки структурных моделей 3D (рис. 1), построенных на основе данных, полученных при детальной или эксплуатационной разведке [1]. При этом существенно увеличивается скорость обработки данных и снижается вероятность ошибок, обусловленных влиянием человеческого фактора.

Традиционная 3D-визуализация геологических данных позволяет представить их в простом и понятном для выполнения проектных работ виде, упрощая процесс принятия технических решений, но несмотря на очевидные преимущества, современные геоинформационные системы обеспечивают только удобный для человека способ хранения и доступа к ранее полученной информации, в то время как обработка, систематизация, обобщение и принятие решений часто выполняются в сторонних геотехнических пакетах, требующих дополнительной обработки ранее полученных данных, в структурированном и понятном для специализированных пакетов формате. Выполнение подобного экспорта

в большинстве случаев невозможно из-за ошибок геометрии, возникающих во время экспортирования, в результате чего необходима ручная обработка. Сократить трудоемкость подготовки геотехнических данных позволяет применение специальных методов геотехнического анализа и интеллектуальных алгоритмов экспорта исходных данных.

Самым подходящим способом, обеспечивающим наилучшие условия применения машинного обучения во время подготовки и анализа данных, является кинематический анализ. Пример его применения при решении задач сдвижения горных пород с использованием алгоритмов искусственного интеллекта приведен в ранее опубликованной работе [2].

Методика обработки данных

Особенность метода заключается в статистическом способе обработки данных структурных нарушений массива горных пород и последующей вероятностной оценке рисков. Ключевым свойством метода является возможность использования данных имеющихся в геологических каркасах 3D структурных нарушений [3, 4] и последующая их обработка статистическими методами.

Сущность метода выделения данных заключается в обработке триангуляционных каркасов геологических объектов и подземных сооружений. В геоинформационных системах эти объекты хранятся в виде сеточных поверхностей, где в качестве элемента сетки выступают треугольные грани, которые несут в себе информацию о ее положении и ориентации в пространстве. Отдельные объекты состоят из нескольких тысяч таких граней, каждая из которых обладает уникальными характеристиками, поэтому и цельные объекты по своей природе являются уникальными и имеют отличительные признаки. Очевидно, что для решения задач кинематического

анализа достаточно знать средние (средневзвешенные) характеристики ориентации граней тектонических нарушений в пространстве, но для систем искусственного интеллекта, обрабатывающих геологические модели 3D без участия человека, необходим расширенный функционал по разделению объектов по схожим признакам в группы или классы. Реализация подобной функции обусловлена необходимостью автоматического выделения из всего набора только тех данных, которые в дальнейшем используются для выполнения специализированных расчетов или анализа, а в качестве дополнительных функций полезно выделить уникальные характеристики каждого объекта, описывающие кривизну или неровность поверхности и оказывающие непосредственное влияние на величину сцепления плоскостей тектонических нарушений.

Действительно, в классических задачах кинематического анализа для оценки состояния блочного массива используется чисто геометрический подход, а величина сцепления между отдельными блоками определяется свойствами тектонических нарушений и, как правило, задается в виде критерия Кулона-Мора. При анализе отдельных поверхностей для каждой из них имеется разброс данных, описывающих ориентацию отдельных граней в пространстве, и в зависимости от формы нарушений они или группируются в локальных областях, или имеют более равномерное (хаотичное) распределение, что указывает на различные значения характеристик сцепления. Полученные таким образом данные могут служить индикатором, характеризующим степень сцепления берегов трещин и извлекаться из сеточных триангуляционных каркасов тектонических нарушений литолого-структурных моделей 3D статистическими методами для последующего использования в ка-

честве дополнительных маркеров при проведении кинематического анализа. Обобщая вышесказанное, можно сделать утвердительное предположение о высокой вероятности использования геологических моделей 3D для последующего извлечения из них данных, необходимых для выполнения кинематического анализа, причем сама структура и формат данных позволяют это сделать простейшими статистическими методами обработки, которые в совокупности с методами машинного обучения позволят выполнять обработку и сортировку данных без участия человека.

Простейшим примером обработки триангуляционных поверхностей является определение собственных значений векторов s_1 , s_2 и s_3 исследуемых поверхностей [5]. В работах [6–8] рассмотрено четыре частных случая.

1. Значение s_1 велико, в то время как значения s_2 и s_3 малы. Это значит, что сумма квадратов перпендикуляров между концевыми точками векторов и осью, соответствующей первому собственному вектору, очень велика. Большинство векторов граней триангуляционной поверхности должно лежать в плоскости, содержащей собственные векторы с номерами 2 и 3, и образовывать опоясывающее распределение на диаграмме Шмита.

2. Оба значения s_1 и s_2 велики, в то время как значение s_3 мало. Расстояние по перпендикуляру от концевых точек до первого и второго собственных векторов должно быть очень большим, а расстояние до третьего собственного вектора должно быть малым. На диаграмме Шмита векторы граней триангуляционной поверхности собираются в пучок вокруг конца третьего собственного вектора. В этом случае как бимодальное, так и унимодальное распределения дают одинаковый результат; они могут различаться только значением результиру-

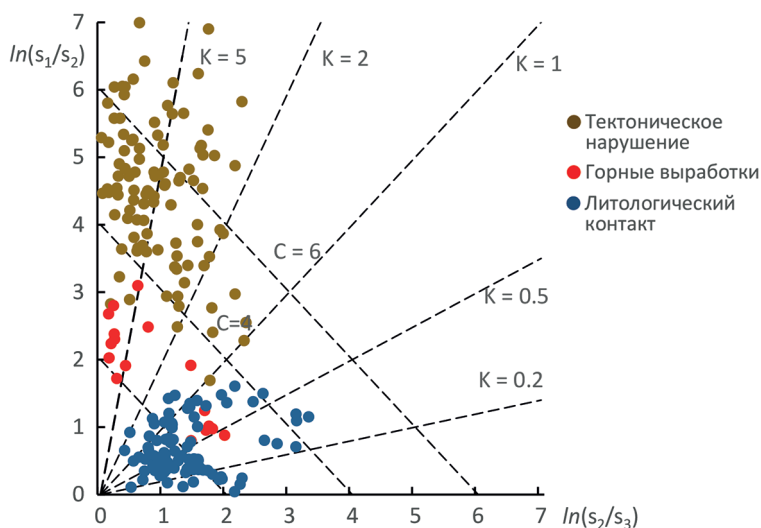


Рис. 2. Размеченные данные, используемые для обучения модели
 Fig. 2. Labeled data used in model learning

ющего вектора, которое для унимодального случая будет большим.

3. Два собственных значения совпадают. Следует отметить, что это некоторый частный случай. Векторы граней образуют симметрический пояс вокруг оси, соответствующей единственному собственному значению.

4. Все три собственных значения одинаковы. Распределение равномерное, так как перпендикулярные направления для трех точек одинаковы для всех трех ортогональных осей. На единичной сфере нет предпочтительного размещения точек.

Вудкок [9] обобщил эти данные и представил в виде логарифмических отношений собственных значений $\ln(s_1/s_2)$ в зависимости от $\ln(s_2/s_3)$ (рис. 2). На его диаграмме все возможные положения точек на сфере попадают в специфические области, и эта форма графического анализа может использоваться при работе с петротектоническими данными [10]. Практические примеры использования коэффициентов Вудкока (K и C) приведены в работах [11, 12]; они применяются для построения геологических карт по данным дистанционного зонди-

рования земной поверхности, поэтому подобные приемы можно использовать для автоматической классификации поверхностей. В геостатистическом моделировании возможно использование дополнительных ковариантов о рельефе местности [13], что позволяет получить значительную долю дисперсии целевых переменных и объяснить 61% дисперсии \log мышьяка (As), 58% дисперсии кальция (оксид, CaO) и 64% дисперсии калия (оксид, K_2O), и концентрации в почве органического углерода [14].

В работе [15] собственные значения векторов и коэффициенты K и C применяются для изучения магнитных и деформационных характеристик синтетектонических гранитов. Изучением анизотропных свойств льда посвящена работа [16], а оценка влияния трещиноватости на направления главных напряжений рассматривается в примерах [17, 18]. Перечень задач, в которых используется информация о характеристиках структурных поверхностей, очень широк, поэтому эти данные могут быть полезными для решения практических задач геомеханики.




Рис. 3. Поверхности: тектоническое нарушение № 1 (а); тектоническое нарушение № 6 (б)
 Fig. 3. Surfaces: fault no. 1 (a); fault no. 6 (b)

В кинематическом анализе учитываются положения ослабленных контактов и тектонических нарушений в пространстве (dip, dip direction), поэтому первоочередной задачей является обучение моделей на выделение из общего набора советующих каркасов. Второй задачей является выделение уникальных характеристик каркасов, таких как угол падения и азимут простираения в пространстве и степень волнистости поверхности. Поэтому на первом этапе алгоритмы машинного обучения используются для обработки триангуляционных каркасов моделей и автоматической классификации каркасов по следующим основным классам: тектоническое нарушение (T), литологический контакт (L), горная выработка (V). Основной целью классификации по данным признакам является задача автоматического выделения только тех каркасов, которые необходимо учитывать. Например, для выполнения кинематического анализа необходимы только класса T и L , но если в

моделях присутствуют горные выработки, то для исключения этих объектов из набора интеллектуальными системами они должны быть правильно классифицированы и исключены из анализа, выполняемого на следующем шаге.

Демонстрация принципа работы алгоритма классификации приводится на примере собственных значений векторов двух каркасов тектонических нарушений (рис. 3), взятых из структурной модели, приведенной на рис. 1. Оба нарушения представлены в виде каркасов и имеют визуальные различия в форме поверхности. Результаты расчета собственных значений векторов и коэффициентов Вудкока (табл. 1) показывают, что поверхности воспринимаются в виде объектов, которые имеют разные свойства, но на диаграммах Шмита оба объекта имеют полное распределение векторов (рис. 4), поэтому могут быть однозначно распознаны алгоритмами машинного обучения как тектонические нарушения, обладающие различными свойствами.

Таблица 1

Результаты анализа собственных значений векторов поверхностей тектонических нарушений
Analysis of eigenvalues of vectors of fault surfaces

Номер нарушения	Dip (угол падения)	Dip Direction (азимут падения)	s_1	s_2	s_3	s_1/s_3	K	C
1	79,85	285,16	0,898951	0,091838	0,009211	97,589	0,992	4,581
6	76,16	86,34	0,972303	0,022932	0,004766	204,022	2,385	5,318

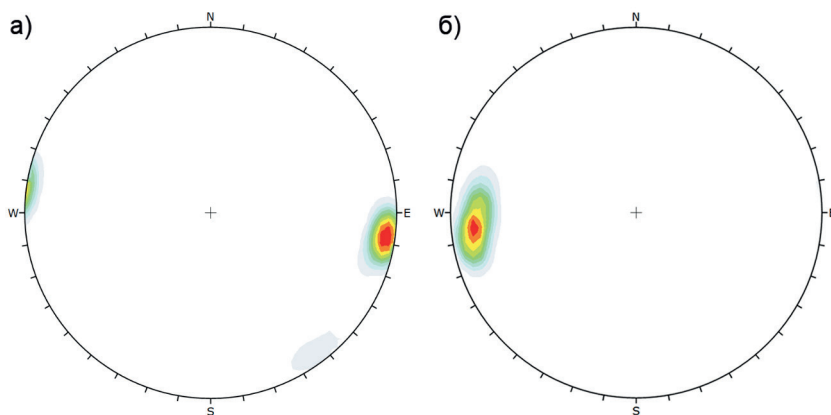


Рис. 4. Диаграммы Шмита: тектоническое нарушение № 1 (а); тектоническое нарушение № 6 (б)
 Fig. 4. Stereographic projection: fault no. 1 (a); fault no. 6 (b)

Зная значения коэффициентов K и C , можно судить о характеристиках поверхности и иметь точные представления о ее свойствах. Коэффициент K показывает распределение данных на диаграмме Шмита, его граничным состоянием является значение $K = 1$. Если $K > 1$, то данные на диаграмме имеют полюсное распределение, а сама поверхность по своей форме будет стремиться к плоскости, что характерно для большинства тектонических нарушений. Если значения $K < 1$, то данные на диаграмме распределяются в виде пояса, а сама поверхность имеет выпуклую (вогнутую) форму.

Примеры описания тектонических нарушений в виде коэффициентов K приведены на рис. 3; если в первом случае тектоническое нарушение № 1 имеет выпуклую (вогнутую) поверхность, а его значение $K = 0,992$, то во втором случае (тектоническое нарушение № 6) поверхность по своей форме ближе к плоскости, а значение $K = 2,385$. Коэффициент C в грубом приближении показывает степень анизотропности поверхности. В крайнем случае при $C = 0$ распределение данных на диаграмме Шмита имеет случайное распределение, что возможно только в том случае, если исследуемая поверхность обладает изотропными свойства-

ми. Такие значения не характерны для тектонических нарушений, для которых значения показателя $C > 4$, и чем оно выше, тем более ярко выраженными анизотропными свойствами обладает поверхность и, как следствие, имеет более высокую вероятность смещения по плоскости нарушения. В рассматриваемом примере наиболее подвижные нарушения будут иметь показатель $C > 6$, поэтому при кинематическом анализе этой группе необходимо уделять особое внимание и задавать минимальные значения показателей сцепления. Обобщая вышесказанное, можно сделать предположение о том, что если опираться только на значения коэффициентов K и C , то с высокой долей вероятности можно выделить тектонические нарушения, которые будут группироваться по признакам $K > 1$ и $C > 4$, что отражено на диаграмме рис. 2.

Несмотря на приведенные выше закономерности, для повышения точности моделей на первом этапе в обучающих примерах используется более широкий спектр входных данных, которые могут оказать даже незначительные влияния на конечный результат, и только на последующих этапах выполняется оптимизация модели по значимости входных

признаков, поэтому в обучающих примерах помимо коэффициентов K и C также используются собственные значения векторов s_1 , s_2 и s_3 .

Выбор обучаемой модели и результаты ее обучения

Используя полученные особенности, выполняется обучение и проверка работоспособности алгоритма по схеме с учителем (рис. 5). В качестве исходных данных используется размеченная литолого-структурная модель, представленная на рис. 1, с добавлением в нее каркасов горных выработок. Общее количество каркасов, используемых для обучения, составило 213. Результаты ручной разметки (приведены на диаграмме рис. 2) имеют признаки группировки, что свидетельствует о высокой вероятности получения модели, обладающей приемлемой точностью классификации.

В качестве обучающей модели использовался многослойный перцептрон (MLP – MultiLayer Perseptron) с одним скрытым слоем, состоящим из 100 нейронов. Построения выполнялись на языке Python с использованием свободно распространяемой библиотеки машинного

обучения Scikit-learn. Обучение модели выполнялось тремя различными методами (табл. 2). Самым простым является стохастический градиентный спуск SGD. Его сущность заключается в поиске максимума функции, он показывает хорошую эффективность в линейных моделях на больших массивах данных, но в рассматриваемом случае имеет самые низкие показатели точности. Более сложной разновидностью является итерационный метод численной оптимизации L-BFGS-B, метод хорошо работает при поиске локальных максимумов/минимумов нелинейных моделей и в данном примере дает наилучшие результаты. Заключительным является метод стохастической оптимизации Adam, который показывает хорошие результаты при обработке больших массивов данных, но в рассматриваемом примере имеет худшие по сравнению с методом L-BFGS-B показатели.

В модели в качестве функции активации применялась сигмоидная (логистическая) функция, которая дает хорошие результаты в задачах классификации. По своей природе сигмоида нелинейна, и комбинация таких функций произво-

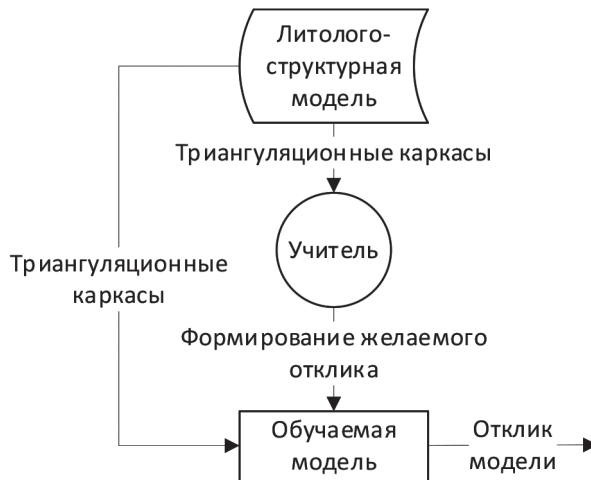


Рис. 5. Схема обучения модели

Fig. 5. Model learning scheme

Таблица 2

Результаты обучения моделей MPL классификации каркасов
Model learning results MPL

Метод обучения	AUC	CA	F1	Precision	Recall	LogLoss	Specification
SGD	0,998	0,921	0,884	0,850	0,922	0,226	0,933
L-BFGS-B	0,988	0,982	0,982	0,983	0,982	0,194	0,994
Adam	0,998	0,940	0,923	0,944	0,940	0,130	0,950

дит также нелинейную функцию, что позволяет уменьшить количество слоев нейронной сети. Еще одно достоинство такой функции — она небинарна и, в отличие от ступенчатой функции, делает активацию аналоговой. Для сигмоиды также характерен гладкий градиент [19, 20]. Следующим преимуществом сигмоидной функции является фиксированный диапазон выходных значений от 0 до 1, тогда как, например, линейная функция может изменяться в пределах $(-\infty, \infty)$. Такое свойство сигмоиды очень полезно, так как не приводит к ошибкам в случае больших значений активации. Благодаря этим свойствам сигмоида является одной из самых часто используемых активационных функций в нейросетях.

Результаты обучения моделей приведены в табл. 2 и свидетельствуют о высокой эффективности моделей классификации каркасов и точности распознавания более 98%.

В задачах машинного обучения оценка качества моделей и сравнение их между собой происходит на основании значений различных метрик.

В табл. 2 приведены значения наиболее популярных метрик, которые применяются для оценки точности моделей классификации [21].

Area Under Curve AUC — площадь, ограниченная ROC-кривой и осью доли ложных положительных классификаций. Чем ближе показатель AUC к единице, тем качественнее работа классификатора, при этом значение 0,5 демонстрирует полную непригодность выбранного

метода классификации и соответствует случайной работе алгоритма.

Classification accuracy CA (точность классификации) — доля правильно классифицированных примеров, является простейшей метрикой оценки работы алгоритма.

Precision (точность) показывает долю объектов, интерпретированных классификатором положительными и при этом действительно являющимися положительными, т.е. показывает способность отличать один класс от другого.

Recall (полнота) показывает, какую долю из всех объектов положительного класса нашел алгоритм, т.е. демонстрирует способность алгоритма обнаруживать класс.

F1 сводит к одному числу два других основополагающих показателя: точность измерений (CA) и полноту (Recall), поэтому, имея в своем распоряжении подобный механизм оценки, проще принять решение о качестве работы алгоритма.

LogLoss логарифмическая функция потерь (кросс-энтропия) измеряет расхождение между двумя вероятностными распределениями. Если кросс-энтропия велика, это означает, что разница между двумя распределениями тоже велика, а если кросс-энтропия мала, то распределения похожи друг на друга.

Specification (специфичность) — способность метода не давать ложноположительных результатов.

Приведенные параметры обучаемой MPL-модели свидетельствуют о высо-

кой точности. Наилучшими показателями обладает модель, обучаемая методом L-BFGS-B, что объясняется наличием нескольких локальных максимумов в классе объекта «горные выработки» и обусловлено отличием в форме каркасов вертикальных и горизонтальных горных выработок.

Точность модели классификации составила 98,2%, она обладает высокой специфичностью, не дает ложноположительные результаты (99,4%).

Выводы

Полученные в работе результаты подготовки и обработки данных позволяют сделать следующие выводы.

- Модели искусственного интеллекта могут применяться для обработки

литолого-структурных моделей и классификации отдельных поверхностей с последующим выделением из них дополнительных данных.

- Классификация поверхностей может осуществляться на основании собственных значений векторов, что подтверждается полученной точностью обученной модели (более 98%).

- Алгоритм искусственного интеллекта позволяет автоматизировать процесс сбора информации о залегании тектонических нарушений, литологических контактов и дополнительных сведений о волнистости и шероховатости поверхностей и применять его для получения данных, используемых в кинематическом анализе и решении задач сдвижения горных пород.

СПИСОК ЛИТЕРАТУРЫ

1. Мельниченко И. А., Кожухов А. А., Омельченко Д. Р., Мосейкин В. В. Построение трехмерной модели месторождения с использованием принципов блочного моделирования и искусственных нейронных сетей // Горный информационно-аналитический бюллетень. — 2022. — № 10. — С. 5–19. DOI: 10.25018/0236_1493_2022_10_0_5.

2. Сергунин М. П., Еременко В. А. Обучение нейронной сети предсказывать параметры сдвижения горных пород налегающей толщи на основании данных о трещиноватости массива на примере рудника «Заполярный» // Горный информационно-аналитический бюллетень. — 2019. — № 10. — С. 106–116. DOI: 10.25018/0236-1493-2019-10-0-106-116.

3. Сергунин М. П., Дарбинян Т. П. Выделение параметров трещиноватости массива горных пород из геологических моделей, построенных в современных геоинформационных системах (на примере Micromine) // Горный журнал. — 2020. — № 1. — С. 39–42. DOI: 10.17580/gzh.2020.01.07.

4. Сергунин М. П., Дарбинян Т. П., Шиленко С. Ю., Гринчук И. П. Обработка цифровой поверхности рудоспуска на предмет выделения направлений главных напряжений и влияния существующей трещиноватости массива // Горный журнал. — 2020. — № 6. — С. 28–32. DOI: 10.17580/gzh.2020.06.04.

5. Ruehlicke B., Carter M. J., Ottesen C. G. The statistical eigenvector analysis technique (SEAT) for dip data analysis // Marine and Petroleum Geology. 2019, vol. 110, pp. 856–870. DOI: 10.1016/j.marpetgeo.2019.07.027.

6. Дэвис Д. С. Статистический анализ данных в геологии. — М.: Недра, 1990. — 319 с.

7. Мардиа К. Статистический анализ угловых наблюдений: пер. с англ. — М.: Наука, 1978. — 240 с.

8. Чини Р. Ф. Статистические методы в геологии: пер. с англ. — М.: Мир, 1986. — 189 с. Литературу с п. 9 по п. 19 смотри в REFERENCES.

20. Соснин А. С., Суслова И. А. Функции активации нейросети: сигмоида, линейная, ступенчатая, relu, tanh / Наука. Информатизация. Технологии. Образование: Материалы XII Международной научно-практической конференции. — Екатеринбург: РГППУ, 2019. — С. 237–246.

21. *Tharwat A.* Classification assessment methods // *Applied Computing and Informatics*. 2021, vol. 17, no. 1, pp. 168–192. DOI: 10.1016/j.aci.2018.08.003. **UAB**

REFERENCES

1. Melnichenko I. A., Kozhukhov A. A., Omelchenko D. R., Moseykin V. V. 3D mineral deposit modeling using concepts of blockmodeling and artificial neural networks. *MIAB. Mining Inf. Anal. Bull.* 2022, no. 10, pp. 5–19. [In Russ]. DOI: 10.25018/0236_1493_2022_10_0_5.

2. Sergunin M. P., Eremenko V. A. Learning of neural network to predict overlying rock mass displacement parameters by the data on jointing in terms of the Zapolyarny Mine. *MIAB. Mining Inf. Anal. Bull.* 2019, no. 10, pp. 106–116. [In Russ]. DOI: 10.25018/0236-1493-2019-10-0-106-116.

3. Sergunin M. P., Darbinyan T. P. Identification of rock mass jointing parameters in geological models in modern geoinformation systems (in terms of Micromine). *Gornyi Zhurnal*. 2020, no. 1, pp. 39–42. [In Russ]. DOI: 10.17580/gzh.2020.01.07.

4. Sergunin M. P., Darbinyan T. P., Shilenko S. Y., Grinchuk I. P. Digital surface modeling of an ore pass to reveal orientation of principal stresses and effect of rock fracturing. *Gornyi Zhurnal*. 2020, no. 6, pp. 28–32. [In Russ]. DOI: 10.17580/gzh.2020.06.04.

5. Ruehlicke B., Carter M. J., Ottesen C. G. The statistical eigenvector analysis technique (SEAT) for dip data analysis. *Marine and Petroleum Geology*. 2019, vol. 110, pp. 856–870. DOI: 10.1016/j.marpetgeo.2019.07.027.

6. Devis D. S. *Statisticheskiiy analiz dannykh v geologii* [Statistics and data analysis in geology], Moscow, Nedra, 1990, 319 p.

7. Mardia K. *Statisticheskiiy analiz uglovykh nablyudeniy*, per. s angl. [Statistics of directional data. English–Russian translation], Moscow, Nauka, 1978, 240 p.

8. Chini R. F. *Statisticheskie metody v geologii*, per. s angl. [Statistical methods in geology for field and lab decisions. English–Russian translation], Moscow, Mir, 1986, 189 p.

9. Woodcock N. H. Specification of fabric shapes using an eigenvalue method. *Geological Society of America Bulletin*. 1977, vol. 88, pp. 1231–1236. DOI: 10.1130/0016-7606(1977)88<1231:SOFSUA>2.0.CO;2.

10. Petri B., Almqvist B. S., Pistone M. 3D rock fabric analysis using micro-tomography: An introduction to the open-source TomoFab MATLAB code. *Computers & Geosciences*. 2020, vol. 138, article 104444. DOI: 10.1016/j.cageo.2020.104444.

11. Caumon G., Gray G., Antoine C., Titeux M. O. Three-dimensional implicit stratigraphic model building from remote sensing data on tetrahedral meshes: Theory and application to a regional model of La Popa Basin, NE Mexico. *IEEE Transactions on Geoscience and Remote Sensing*. 2013, vol. 3, no. 51, pp. 1613–1621. DOI: 10.1109/TGRS.2012.2207727.

12. Kokkalas S., Xypolias P., Koukouvelas I. K., Doutsos T. Relationships between Folding and Fracturing in Orogenic Belts: Examples from the Rhenohercynian Zone (Germany) and the External Hellenides (Greece). *Geologica Carpathica*. 2003, vol. 54, pp. 153–162.

13. Kirkwood C. Deep covariate-learning: Optimising information extraction from terrain texture for geostatistical modelling applications. *ArXiv preprint*. 2020, p. 14. DOI: 10.48550/arXiv.2005.11194.

14. Mallik S., Bhowmik T., Mishra U., Paul N. Mapping and prediction of soil organic carbon by an advanced geostatistical technique using remote sensing and terrain data. *Geocarto International*. 2020, vol. 37, pp. 2198–2214.

15. Acharyya S. S., Mondal T. K. Magnetic shape fabric analysis from syntectonic granites: a study based on the eigenvalue method. *Geological Magazine*. 2022, vol. 160, pp. 222–234. DOI: 10.1017/S0016756822000747.

16. Rathmann N. M., Hvidberg C. S., Grinsted A., Lilien D. A., Dahl-Jensen D. Effect of an orientation-dependent non-linear grain fluidity on bulk directional enhancement factors. *Journal of Glaciology*. 2021, vol. 67, no. 263, pp. 569–575. DOI: 10.1017/jog.2020.117.

17. Whitaker A. E., Engelder T. Characterizing stress fields in the upper crust using joint orientation distributions. *Journal of Structural Geology*. 2005, vol. 27, pp. 1778–1787. DOI: 10.1016/J.JSG.2005.05.016.

18. Tavani S., Corradetti A., Matteis M. D., Iannace A., Mazzoli S., Castelluccio A., Spanos D., Parente M. Early-orogenic deformation in the Ionian zone of the Hellenides: Effects of slab retreat and arching on syn-orogenic stress evolution. *Journal of Structural Geology*. 2019, vol. 124, pp. 168–181. DOI: 10.1016/j.jsg.2019.04.012.

19. Elfving Stefan, Uchibe Eiji, Doya Kenji. Sigmoid-weighted linear units for neural network function approximation in reinforcement learning. *Neural Networks*. 2018, vol. 107, pp. 3–11. DOI: 10.1016/j.neunet.2017.12.012.

20. Sosnin A. S., Suslova I. A. Neural network activation functions: sigmoid, linear, stepped, relu, than. *Nauka. Informatizatsiya. Tekhnologii. Obrazovanie: Materialy XII Mezhdunarodnoy nauchno-prakticheskoy konferentsii* [Scientific. Informatization. Technologies. Education: Proceedings of the XII International Scientific and Practical Conference], Ekaterinburg, RGPPU, 2019, pp. 237–246. [In Russ].

21. Tharwat A. Classification assessment methods. *Applied Computing and Informatics*. 2021, vol. 17, no. 1, pp. 168–192. DOI: 10.1016/j.aci.2018.08.003.

ИНФОРМАЦИЯ ОБ АВТОРАХ

Сергунин Максим Петрович – начальник отдела
Центра геодинамической безопасности,
Заполярный филиал ПАО «ГМК «Норильский никель»,
e-mail: SerguninMP@nornik.ru,
ORCID ID: 0000-0002-7774-6826,

Еременко Виталий Андреевич – д-р техн. наук,
профессор РАН, директор научно-исследовательского
центра «Прикладная геомеханика и конвергентные
горные технологии», профессор кафедры физических
процессов горного производства и геоконтроля,
Горный институт НИТУ «МИСиС»,
e-mail: prof.eremenko@gmail.com, ORCID ID: 0000-0003-1478-6916.

Для контактов: Сергунин М.П. e-mail: SerguninMP@nornik.ru.

INFORMATION ABOUT THE AUTHORS

M.P. Sergunin, Head of Department,
Center for Geodynamic Safety, Polar Division
of MMC Norilsk Nickel, Norilsk, Russia,
e-mail: SerguninMP@nornik.ru,
ORCID ID: 0000-0002-7774-6826,
V.A. Eremenko, Dr. Sci. (Eng.),
Professor of Russian Academy of Sciences,
Director of the Research Center for Applied Geomechanics
and Convergent Technologies in Mining,
Professor at Department of Physical Processes in Mining and Geocontrol,
Mining Institute, National University of Science
and Technology «MISiS», 119049, Moscow, Russia,
e-mail: prof.eremenko@gmail.com, ORCID ID: 0000-0003-1478-6916.

Corresponding author: M.P. Sergunin, e-mail: SerguninMP@nornik.ru.

Получена редакцией 06.06.2023; получена после рецензии 26.06.2023; принята к печати 10.08.2023.
Received by the editors 06.06.2023; received after the review 26.06.2023; accepted for printing 10.08.2023.