

УДК 528.94+[004.925.83:550.3]  
DOI 10.33764/2411-1759-2024-29-2-108-117

## Использование методов машинного обучения в геоинформационных моделях при решении задач геофизической разведки

И. Ю. Степанов<sup>1</sup>✉

<sup>1</sup> Кемеровский государственный университет, г. Кемерово, Российская Федерация  
e-mail: zextel1995@gmail.com

**Аннотация.** Рассматривается возможность применения нейронных сетей для анализа данных, полученных в ходе сейсмических исследований. Установлено, что разрывные нарушения угольного массива негативно влияют на пространственную структуру данных. Процесс детектирования таких нарушений определяет повышенные требования к точности их позиционирования в пространстве геологического тела. Отмечается, что точное обнаружение таких нарушений требует использования современных технологий, в том числе таких инструментов, как методы машинного обучения и искусственного интеллекта. Исследовано использование сверточных нейронных сетей, автоэнкодеров и комбинированных архитектур для обнаружения дизъюнктивных нарушений в геологических структурах. Проведено сравнение нейросетевых архитектур на их применимость в задачах выявления дизъюнктивных нарушений в исследуемой области. Приведены результаты сравнения указанных архитектур на подготовленной выборке геоданных. Предложена методика интерпретации результатов.

**Ключевые слова:** разрывные нарушения, искусственный интеллект, сверточные нейронные сети, автоэнкодеры, комбинированные архитектуры, геологические структуры

### Введение

Нарушение сплошности породного массива при отработке угольных пластов является достаточно частым явлением. Такие нарушения могут быть образованы в результате тектонического движения горных пород, смещения их по разломам и т. п.; при этом присутствовать локально или охватывать весь массив, имея соответственно локальные или относительно однородные характеристики по всему массиву [1]. В связи с этим образуются разрывные нарушения, которые представляют собой нарушение сплошности массива горных пород, фиксируемое по относительному перемещению разобщенных частей массива по поверхности скола. Результаты исследований подобных фактов в Кузбассе свидетельствуют о значительном числе подобных разрывных нарушений горных пород в виде грабен и горстов [2]. Подобным примером, по-видимому, является катастрофический случай на одном из рудников в Амурской области («Российская газета» от 20.03.2024).

Неоднородность состава, структуры, свойств и распределения напряжений породного массива, разнообразие размеров и взаимного расположения обнажений зачастую оказывают решающее значение на безопасность и эффективность ведения горных работ. Для обеспечения стабильной и высокопроизводительной работы очистного забоя необходимо тщательно исследовать выемочный блок на предмет установления вида разрывного нарушения, если таковой имеется, и выявления геометрических параметров этого нарушения. Это позволяет разрабатывать адекватные технологии и рекомендации по управлению механизированными крепями при отработке угольных пластов, обеспечивая качество вынимаемого сырья и эффективность ведения горных работ [3].

С использованием арсенала методов сейсморазведки возможно выявление разрывных нарушений с достаточно высокой точностью. Однако получаемые сигналы такой разведки зачастую искажены в силу неоднородности горного массива, в них также присутствуют

посторонние сигналы деятельности человека, а также случайные сигналы – шумы [4].

### ***О перспективах использования методов искусственного интеллекта в геоинформатике***

Для более эффективной обработки геофизических и геологических данных целесообразно применять современные технологии и инструменты, позволяющие задействовать более комплексные виды анализа и расширять круг решаемых задач, что было продемонстрировано, например, авторами [5], [6] и [7]. Решение задачи обнаружения дизъюнктивных нарушений в углепородных массивах не является исключением – в частности, это позволяет получать более достоверную информацию для принятия управленческих решений при отработке угольных пластов. Одним из таких инструментов является внедрение методов машинного обучения, которые позволят автоматически обрабатывать большие объемы данных и выделять наиболее значимые признаки [8].

Применение алгоритмов искусственного интеллекта в рамках специализированных геоинформационных систем совместно с производственными системами поддержки принятия решений позволят не только обнаруживать дизъюнктивные нарушения в пределах выемочного участка, но и предлагать комплексы мероприятий в рамках плана ведения горных работ [9]. Модели фильтрации, базирующиеся на моделях, использующих обучение с подкреплением, могут применяться в решениях хранения и обеспечения геопространственными данными, например, как в системе, предлагаемой авторами [10]. Использование таких информационно-аналитических систем позволит существенно повысить эффективность и точность обнаружения дизъюнктивных нарушений в угольных массивах, что является важным шагом в обеспечении безопасности горных работ и сохранении окружающей среды.

Использование моделей и алгоритмов искусственного интеллекта в сфере геологии находит свое применение в различных задачах. Авторами [11] было продемонстриро-

вано применение глубоких нейронных сетей для решения задачи картирования тектонических нарушений. В работе [12] была использована глубокая нейронная сеть для классификации вещественного состава геологического тела. А в источнике [13] автор проводит сравнительный анализ сверточной нейросетевой архитектуры UNet для применимости в задачах сегментации сейсмических горизонтов.

Сейсмограммы часто содержат шум из различных источников, и автоэнкодеры могут эффективно фильтровать этот шум, сохраняя при этом важные характеристики. Использование методов глубокого обучения обосновывается высокой операционной стоимостью применения классических способов обработки зашумленных данных, с точки зрения временных и вычислительных ресурсов. Особенно полезным применением современных нейросетевых архитектур является их адаптивность к тому, что размеченные данные о дизъюнктивных нарушениях могут быть несбалансированными по количеству прецедентов, т. е. на относительно большое количество данных с участков без дизъюнктивных нарушений найдется лишь небольшое количество областей, на которых эти нарушения будут иметься.

### ***Анализ подходов выявления дизъюнктивных нарушений. Подход Data-driven, использование автоэнкодеров***

Для поиска дизъюнктивных нарушений в геологических структурах без использования машинного обучения и искусственного интеллекта обычно применяются методы геологического картирования и геофизического исследования. Проводятся наблюдения в полевых условиях, с использованием различных инструментов для измерения геологических параметров, в частности, электрического сопротивления [14], магнитного и гравитационного полей и т. д. [15]. Затем на основе полученных данных строят геологические карты и анализируют их на предмет наличия дизъюнктивных нарушений. Этот процесс является достаточно трудоемким, требует значи-

тельного количества времени и ресурсов. Кроме того, полученные результаты могут быть подвержены ошибкам, связанным с субъективным восприятием исследователя.

Дальнейший процесс связан с исследованиями, направленными на моделирование состояния породного массива с дизъюнктивными нарушениями. Так, авторы [16] рассматривают применение метода конечных элементов для моделирования выбросоопасного состояния массива с дизъюнктивным нарушением в горной выработке. Другое направление исследований указывает на автоматизацию поиска нарушений сплошности породных тел. Так, в работе [17] исследуются данные, полученные с помощью геофизических методов, таких как электроразведка и сейсмическая томография. Для их обработки использованы методы машинного обучения, такие как нейронные сети и классификаторы. В результате предложена система, позволяющая автоматически обнаруживать дизъюнктивные нарушения в угольных массивах с высокой точностью.

В работе [18] представлен обзор методов машинного обучения в микросейсмическом мониторинге. Такие методы могут быть применимы для сейсмических исследований по-

родного массива – метода исследования геологических структур, который основывается на изучении распространения звуковых волн в породах. При проведении сейсмического исследования на поверхности земли устанавливаются геофоны, которые регистрируют отраженные от пород звуковые волны, создаваемые источником колебаний, расположенным на дневной поверхности [19]. Анализируя данные, полученные в результате сейсмических наблюдений, исследователи могут определить наличие дизъюнктивных нарушений в породном массиве.

В результате проведения сейсмического исследования породного массива в качестве выходных данных исследователи получают набор файлов сейсмотрасс – массивов данных, которые отражают изменения амплитудно-частотных характеристик распространения звуковых волн в породах при проведении сейсмического исследования [20]. Для получения сейсмограммы на поверхности земли устанавливаются геофоны, регистрирующие отраженные от пород звуковые волны, которые создаются источником колебаний на поверхности [21]. Полученные данные обрабатывают и преобразуют в графическое изображение – сейсмограмму, пример которой представлен на рис. 1.

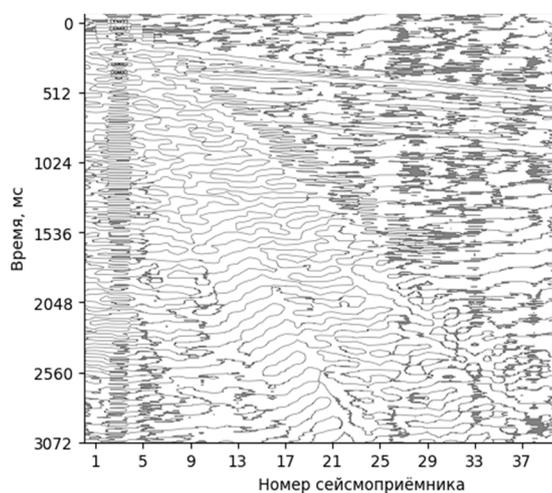


Рис. 1. Пример получаемой сейсмограммы

С точки зрения данных, сейсмограмма представляет собой многомерный геоинформационный объект, который содержит не только спектрально-амплитудные свойства сейсмических волн, но и включает в себя геопростран-

ственные метаданные, необходимые для проведения пространственного анализа. В силу гетерогенности земной поверхности важно учитывать пространственные характеристики геофонов, такие как их географическое положение, гео-

метрию измерений, параметры радарной системы и прочие факторы [22].

Для локализации области дизъюнктивных нарушений углепородного массива по сейсмограмме могут использоваться различные архитектуры нейронных сетей; наиболее часто используются сверточные нейронные сети (Convolutional Neural Networks).

Архитектура нейронной сети должна включать в себя сверточные слои с ядрами различных размеров, пулинговые слои для уменьшения размерности данных и полносвязные слои для классификации и локализации дизъюнктивных нарушений. Также можно использовать методы объединения, такие как фильтрация, сегментация и кластеризация, для улучшения точности и эффективности модели.

Однако можно встретить примеры использования рекуррентных нейронных сетей (Recurrent Neural Networks, RNN), комбинированных архитектур и т. д. Например, в работе [23] авторы использовали сверточную нейронную сеть для локализации областей дислокаций в горных породах по данным пассивной сейсмической томографии. В другой статье

[24] авторы использовали комбинацию сверточной и рекуррентной нейронных сетей для обнаружения дизъюнктивных нарушений в плотных песчаниках Сычуаньского бассейна.

Активно ведутся исследования по применению передовых нейросетевых методов для локализации аномалий по данным, полученным в результате сейсморазведки. Одним из эффективных методов является использование автоэнкодеров для обнаружения аномалий в сейсмических данных [25]. Авторы показали, что автоэнкодеры могут быть в локализации аномалий на сейсмических данных.

Отметим, что автоэнкодеры представляют собой нейронные сети, которые используются для обработки данных с целью их сжатия и восстановления. Они отличаются от классических сетей прямого распространения тем, что имеют два слоя: кодировщик и декодировщик. Кодировщик преобразует входные данные в компактное представление, а декодировщик восстанавливает исходные данные из этого представления [26]. Операционные графы глубокого и вариационного автоэнкодеров приведены на рис. 2.

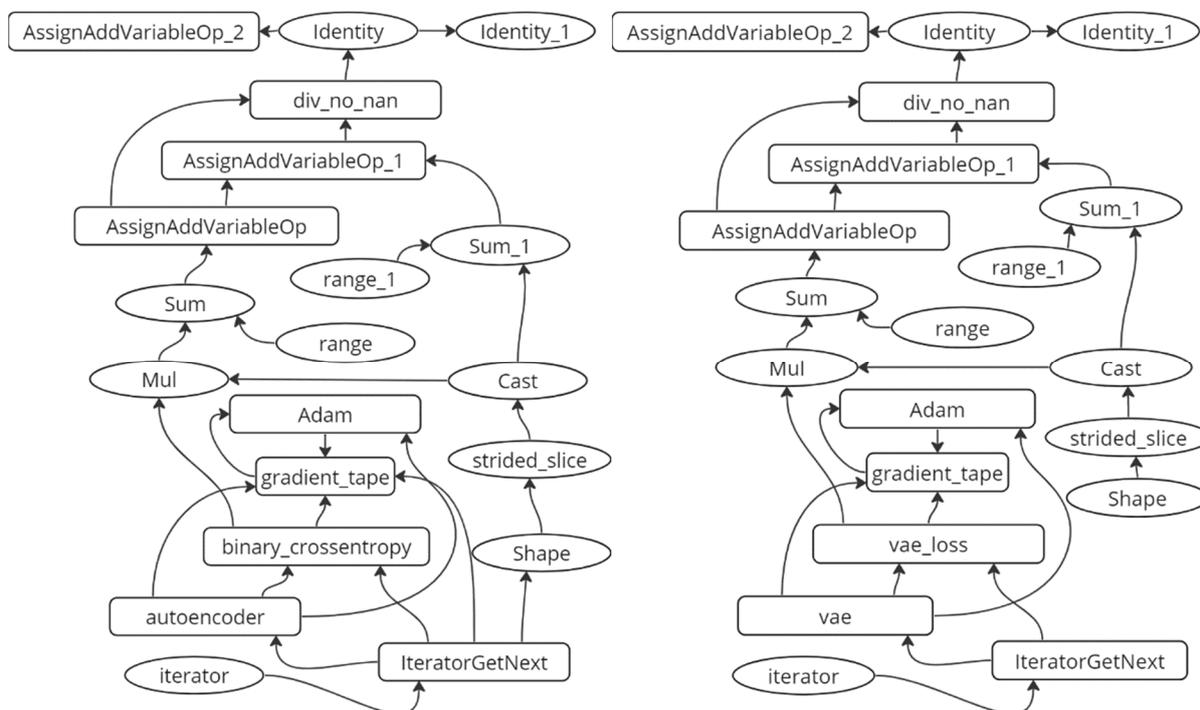


Рис. 2. Операционные графы глубокого и вариационного автоэнкодеров

Указанные архитектуры могут быть использованы для различных задач, таких как

извлечение признаков, анализ и генерация новых данных. В качестве преимуществ исполь-

зования автоэнкодеров, по сравнению с классическими архитектурами сетей прямого пространства, являются:

- способность обрабатывать данных, содержащих шум, и восстанавливать их без потери качества, ввиду того что они не просто копируют входные данные, а строят их компактное представление;

- способность к сжатию данных с сохранением их основных характеристик и описательных статистик;

- обучение без учителя, что позволяет использовать их для анализа больших объемов неструктурированных данных [27].

Важно отметить, что процесс обучения автоэнкодера будет отличаться от использования остальных моделей ввиду особенностей решаемой задачи. Задача детектирования аномалий есть частный случай несбалансированной по классам задачи классификации, поэтому в качестве входного набора данных используется лишь один набор – «нормальными» данными, не являющимися аномалиями [28].

В терминах исследуемой проблемы обучающая выборка автоэнкодера состоит из сейсмограмм исследованных областей с сохранением геопространственной информации по геофонам, с подтвержденным экспертом отсутствием дизъюнктивных нарушений. Для каскадной нейронной сети обучение проводилось на массиве из сейсмотрасс, дополни-

тельно к которым передавался вектор, содержащий сведения о том, есть ли нарушение на сейсмограмме или нет.

### Результаты и их обсуждение

В качестве итогового результата в дополнение к проведенному анализу возможностей выявления, исследования и картирования разрывных дизъюнктивных нарушений проведен вычислительный эксперимент, результаты которого представлены в таблице. В эксперименте использованы: каскадная нейронная сеть (NN), глубокий автоэнкодер (DAE), сверточный автоэнкодер (CNN) и вариационный автоэнкодер (VAE).

С целью более объективной интерпретации результатов использовано несколько подходов. Так, для случая каскадной нейронной сети и анализа результатов ее работы определялась вероятность наличия разрывного нарушения на сейсмограмме: при ее значении больше 0,5 сейсмограмма получала метку наличия разрывного нарушения, а при значении 0 – метку его отсутствия.

Для автоэнкодеров использовалась пороговая функция: при превышении 5 % отклонения по метрике MAPE сейсмограмма получала метку наличия разрывного нарушения, в ином случае такая метка отсутствовала.

Результаты сравнения алгоритмов автоэнкодеров

Алгоритм	NN	DAE	CAE	VAE
Loss (обучение)	0,4133	0,6740	0,6061	0,0338
Loss (валидация)	0,5791	0,6924	0,6049	0,1752
Accuracy (валидация)	0,6598	0,5975	0,6934	0,8317

Следует отметить, что лучшую точность по результатам анализа валидационной выборки продемонстрировал вариационный автоэнкодер. Разница в качестве моделей обуславливается как особенностями архитектуры, так и реализацией каждой из моделей. Так, VAE чаще используется для генерации новых объектов, нежели чем для решения задач классификации. Это связано с тем, что в архитектуре VAE используется оценивание плотности вероятности с дальнейшим восстановлением по предсказанному представлению. Тем самым повышается сложность интерпретации результатов работы модели, поскольку значения классических метрик оценки качества моделей могут иметь большие погрешности. В частности, для оценки качества VAE используется комбинация оценки восстановления (reconstruction loss) и расстояния Кульбака – Лейблера, нежели чем бинарная кросс-энтропия для NN, DAE и CAE [29].

### Заключение

Обобщая изложенное, сделаем следующие выводы:

– использование современного инструментария геоинформатики, в частности, моделей, глубокого машинного обучения, позволяет исследователю актуальных задач геофизической разведки заметно повысить точность ее результатов в сравнении с традиционными методами; при этом внимания заслуживает процесс адаптации исследуемых моделей;

– применение автоэнкодеров для решения задач поиска дизъюнктивных нарушений углепородного массива может сократить время на классификацию сейсмограмм и локализацию нарушений, а в дальнейшем эффективно адаптировать используемую модель для генерации подобных сейсмограмм.

### БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Короновский Н. В. Общая геология : учеб. пособие. – М. : КДУ, Добросвет, 2018. – С. 430–448.
2. Опарин В. Н., Адушкин В. В., Киряева Т. А., Потапов В. П. Региональная кластеризация угольных месторождений Кузбасса по газодинамической активности. Ч. II: влияние геотермических, геодинамических и физико-химических процессов // Горный информационно-аналитический бюллетень. – 2018. – № 10. – С. 5–29.
3. Смирнов А. В., Ремезов А. В. Факторы, влияющие на безопасную и высокопроизводительную работу очистных забоев [Электронный ресурс] // Вестник КузГТУ. – 2005. – № 4.1. – Режим доступа: <https://cyberleninka.ru/article/n/factory-vliyayuschie-na-bezopasnuyu-i-vysokoproizvoditelnuyu-rabotu-ochistnyh-zaboev/viewer>.
4. Семерикова И. И. Возможности методики распознавания зон трещиноватости по сейсмическим параметрам для изучения техногенных изменений состояния пород [Электронный ресурс] // Горный информационно-аналитический бюллетень. – 2011. – № 2. – Режим доступа: <https://cyberleninka.ru/article/n/vozmozhnosti-metodiki-raspoznaniya-zon-treschinovatosti-po-seysmicheskim-parametram-dlya-izucheniya-tehnogennyh-izmeneniy/viewer>.
5. Басаргин А. А. Применение методов геоинформатики для изучения и оценивания риска последствий землетрясений // Вестник СГУГиТ. – 2022. – Т. 27, № 6. – С. 89–97.
6. Бугакова Т. Ю., Шарапов А. А. Совершенствование методов визуального осмотра зданий и инженерных сооружений путем внедрения технологий компьютерного зрения и интеллектуальной обработки данных // Вестник СГУГиТ. – 2022. – Т. 27, № 6. – С. 108–119.
7. Янкелевич С. С. Развитие тематической картографии на базе геопространственных знаний и когнитивного подхода // Вестник СГУГиТ. – 2022. – Т. 27, № 4. – С. 122–127.
8. Бабина Л. А., Кочетков В. М. Применение методов машинного обучения для обработки геофизических данных // Изв. вузов. Геология и разведка. – 2014. – № 4. – С. 42–48.
9. Ахмедов А. А., Адамов Д. У. Применение алгоритмов машинного обучения для разработки геофизической модели месторождений // Междунар. журнал прикладных и фундаментальных исследований. – 2017. – Т. 4, № 5. – С. 792–796.
10. Авдеев В. А., Яблонский Л. И. Возможный вариант формализации интегрированной системы обеспечения пространственными данными // Вестник СГУГиТ. – 2023. – Т. 28, № 5. – С. 41–50.
11. Мифтахов Р. Ф., Авдеев П. А., Гогоненков Г. Н., Базанов А. К., Ефремов И. И. Картирование тектонических нарушений на основе машинного обучения и нейронных сетей // Геология нефти и газа. – 2021. – № 3. – С. 123–136. – DOI 10.31087/0016-7894-2021-3-123-136.
12. Темникова Е. Ю., Грубась С. И., Федосеев А. А. Литологическая интерпретация данных в ГИС в интервалах Баженовской свиты с использованием искусственных нейронных сетей // Интерэкспо ГЕО-Сибирь. XVII Междунар. науч. конгр. : Междунар. науч. конф. «Недропользование. Горное дело. Направления и технологии поиска, разведки и разработки месторожде-

ний полезных ископаемых. Экономика. Геоэкология» (Новосибирск, 19–21 мая 2021 г.) : сб. материалов в 8 т. – Новосибирск : СГУГиТ, 2021. Т. 2, № 3. – С. 3–9. – DOI 10.33764/2618-981X-2021-2-3-3-9.

13. Канониров А. П. Сравнительный анализ применения 2D/3D сегментационных моделей в задаче выделения сейсмических горизонтов [Электронный ресурс] // Экспозиция Нефть Газ. – 2022. – № 8. – Режим доступа: <https://cyberleninka.ru/article/n/sravnitelnyu-analiz-primeneniya-2d-3d-segmentatsionnyh-modeley-v-zadache-vydeleniya-seysmicheskikh-gorizontov/viewer>.

14. Волкова Е. Н., Казначеев П. А., Камшилин А. Н., Попов В. В. Геоэлектрические исследования процессов подготовки провалов грунта // Геофизические исследования. – 2013. – Т. 14, № 3. – С. 64–79.

15. Кушнарев И. П. Методы изучения разрывных нарушений – М. : Недра, 1977. – С. 42–48.

16. Исабек Т. К., Хуанган Н., Айтпаева А. Р., Шаймерденова Р. Т. Моделирование выбросоопасного состояния массива с дизъюнктивным нарушением и горной выработкой методом конечных элементов // Уголь. – 2020. – № 6. – DOI 10.18796/0041-5790-2020-6-55-61.

17. Malhotra R. A systematic review of machine learning techniques for software fault prediction // Applied Soft Computing. – 2015. – Vol. 27. – P. 504–518. – DOI 10.1016/j.asoc.2014.11.023.

18. Anikiev D., Birnie C., bin Waheed U., Alkhalifah T., Gu C., Verschuur D. J., Eisner L. Machine learning in microseismic monitoring // Earth-Science Reviews. – 2023. – Vol. 239. – DOI 10.1016/j.earscirev.2023.104371.

19. Беляева Л. И. Основы геофизики : учеб. пособие. – Ухта : УГТУ, 2016. – С. 75–82.

20. Молев М. Д. Методологические аспекты выбора комплекса геофизических методов исследования массива горных пород [Электронный ресурс] // Горный информационно-аналитический бюллетень. – 1999. – № 6. – Режим доступа: <https://cyberleninka.ru/article/n/metodologicheskie-aspekty-vybora-kompleksa-geofizicheskikh-metodov-issledovaniya-massiva-gornyh-porod/viewer>.

21. Краснов В. И., Исаев В. И. Применение методов искусственного интеллекта для анализа геофизических данных // Вестник РГГРУ. – 2018. – № 1 (86). – С. 98–105.

22. Одабаи-Фард В. В., Пономаренко М. Р. Геодинамический мониторинг земной поверхности и объектов горнодобывающей промышленности при помощи метода радарной интерферометрии // Горный информационно-аналитический бюллетень. – 2017. – № 11. – DOI 10.25018/0236-1493-2017-11-0-59-67.

23. Adler A., Araya-Polo M., Poggio T. Deep Recurrent Architectures for Seismic Tomography [Electronic resource] // 81st EAGE Conference & Exhibition. – 2019. – Mode of access: <https://arxiv.org/ftp/arxiv/papers/1908/1908.07824.pdf>.

24. Qian K. A., Guo D., Xiang X., Qiao Y. Two-Step Method for Prediction of Fractured Tight Sandstone Reservoir in Northeast Sichuan Basin // 82nd EAGE Annual Conference Exhibition. – 2021. – DOI 10.3997/2214-4609.202112900.

25. Fisher W., Camp T., Krzhizhanovskaya V. Anomaly Detection in Earth Dam and Levee Passive Seismic Data Using Support Vector Machines and Automatic Feature Selection // Journal of Computational Science. – 2016. – DOI 10.1016/j.jocs.2016.11.016.

26. Акинина Н. В., Акинин М. В., Соколова А. В., Никифоров М. Б., Таганов А. И. Автоэнкодер: подход к понижению размерности векторного пространства с контролируемой потерей информации [Электронный ресурс] // Известия ТулГУ. Технические науки. – 2016. – № 9. – Режим доступа: <https://cyberleninka.ru/article/n/avtoenkoder-podhod-k-ponizheniyu-razmernosti-vektornogo-prostranstva-s-kontroliruemoj-poterey-informatsii/viewer>.

27. Дык Буй Минь, Хуи Нгуен Нгок, Линь Лай Тхи, Хю Нгуен Ба, Чьонг Нгуен Динь, Лам Нгуен Чонг. Сжатие данных [Электронный ресурс] // Проблемы науки. – 2017. – № 1 (83). – Режим доступа: <https://cyberleninka.ru/article/n/szhatie-dannyh/viewer>.

28. Сафронов Д. А., Кацер Ю. Д., Зайцев К. С. Поиск аномалий с помощью автоэнкодеров [Электронный ресурс] // International Journal of Open Information Technologies. – 2022. – № 8. –



leninka.ru/article/n/vozmozhnosti-metodiki-raspoznavaniya-zon-treschinovatosti-po-seysmicheskim-parametram-dlya-izucheniya-tehnogennyh-izmeneniy/viewer.

5. Basargin, A. A. (2022). Application of geoinformatics methods for studying and assessing the risk of earthquake consequences. *Vestnik SGUGiT [Vestnik SSUGT]*, 27(6), 89–97 [in Russian].

6. Bugakova, T. Yu., & Sharapov, A. A. (2022). Improvement of methods of visual inspection of buildings and engineering structures through the introduction of computer vision technologies and intelligent data processing. *Vestnik SGUGiT [Vestnik SSUGT]*, 27(6), 108–119 [in Russian].

7. Yankelevich, S. S. (2022). The development of thematic cartography based on geospatial knowledge and a cognitive approach. *Vestnik SGUGiT [Vestnik SSUGT]*, 27(4), 122–127 [in Russian].

8. Babina, L. A., & Kochetkov, V. M. (2014). Application of machine learning methods for mining geophysical data. *Izvestiya vuzov. Geologiya i razvedka [Izvestia of universities. Geology and exploration]*, 4, 42–48 [in Russian].

9. Akhmedov, A. A., & Adamov, D. U. (2017). Application of machine learning algorithms for the development of a geophysical model of deposits. *Mezhdunarodnyy zhurnal prikladnykh i fundamental'nykh issledovaniy [International Journal of Applied and Fundamental Research]*, 4(5), 792–796 [in Russian].

10. Avdeev, V. A., & Yablonsky, L. I. (2023). A possible variant of the formalization of an integrated spatial data management system. *Vestnik SGUGiT [Vestnik SSUGT]*, 28(5), 41–50 [in Russian].

11. Miftakhov, R. F., Avdeev, P. A., Gogonenkov, G. N., Bazanov, A. K., & Efremov, I. I. (2021). Mapping tectonic faults based on machine learning and neural networks. *Geologiya nefi i gaza [Geology of Oil and Gas]*, 3, 123–136. DOI 10.31087/0016-7894-2021-3-123-136.

12. Temnikova, E. Yu., Grubas, S. I., & Fedoseev, A. A. (2021). Lithological interpretation of data in GIS in the intervals of the Bazhenov formation using artificial neuron networks. In *Sbornik materialov Interekspo GEO-Sibir'-2021: Mezhdunarodnoy nauchnoy konferentsii: T. 2, no. 3. Nedropol'zovanie. Gornoe delo. Napravleniya i tekhnologii poiska, razvedki i razrabotki mestorozhdeniy poleznykh iskopaemykh. Ekonomika. Geoekologiya [Proceedings of Interexpo GEO-Siberia-2021: International Scientific Conference: Vol. 2, No. 3. Subsoil Use. Mining Engineering. Directions and Technologies for Searching, Exploration and Development of Mineral Deposits. Economy. Geoecology]* (pp. 3–9). Novosibirsk: SSUGT Publ. DOI 10.33764/2618-981X-2021-2-3-3-9 [in Russian].

13. Gunners, A. P. (2022). Comparative Analysis of 2D/3D Segmentation MOD Application in Seismic Horizon Identification. *Ekspozitsiya Neft' Gaz [Oil Gas Exposure]*, No. 8. Retrieved from <https://cyberleninka.ru/article/n/sravnitelnyy-analiz-primeneniya-2d-3d-segmentatsionnyh-modely-v-zadache-vydeleniya-seysmicheskikh-gorizontov/viewer> [in Russian].

14. Volkova, E. N., Kaznacheev, P. A., Kamshilin, A. N., & Popov, V. V. (2013). Geoelectric processes of soil failure preparation. *Geofizicheskie issledovaniya [Geophysical Studies]*, 14(3), 64–79 [in Russian].

15. Kushnarev, I. P. (1977). *Metody izucheniya razryvnykh narusheniy [Methods of studying breaking violations]* (pp. 42–48). Moscow: "Nedra" Publ. [in Russian].

16. Isabek, T. K., Huanggang, N., Aitpaeva, A. R., & Shaymerdenova, R. T. (2020). Modeling of the you-throwing state of the massif with disjunctive disturbance and mining with finite element mode. *Ugol' [Coal]*, No. 6. DOI 10.18796/0041-5790-2020-6-55-61.

17. Malhotra, R. (2015). A systematic review of machine learning techniques for software fault prediction. *Applied Soft Computing*, 27, 504–518. DOI 10.1016/j.asoc.2014.11.023.

18. Anikiev, D., Birnie, C., bin Waheed, U., Alkhalifah, T., Gu, C., Verschuur, D. J., & Eisner, L. (2023). Machine learning in microseismic monitoring. *Earth-Science Reviews*, Vol. 239. DOI 10.1016/j.earscirev.2023.104371.

19. Belyaeva, L. I. (2016). *Osnovy geofiziki [Fundamentals of geophysics]* (pp. 75–82). Ukhta: UGTU Publ. [in Russian].

20. Molev, M. D. (1999). Methodological aspects of the choice of a set of geophysical methods for studying the rock mass. *Gornyy informatsionno-analiticheskiy byulleten' [Mining Information and Analytical Bulletin]*, No. 6. Retrieved from <https://cyberleninka.ru/article/n/metodologicheskie-aspekty-vybora-kompleksa-geofizicheskikh-metodov-issledovaniya-massiva-gornyh-porod/viewer> [in Russian].
21. Krasnov, V. I., & Isaev, V. I. (2018). The use of artificial intelligence methods for analyzing geophysical data. *Vestnik RGGRU [Bulletin of the Russian State Pedagogical University]*, 1(86), 98–105 [in Russian].
22. Odabai-Fard, V. V., & Ponomarenko, M. R. (2017). Geodynamic monitoring of the Earth's top and mining facilities using the radar interferometry method. *Gornyy informatsionno-analiticheskiy byulleten' [Mining Information and Analytical Bulletin]*, No. 11. DOI 10.25018/0236-1493-2017-11-0-59-67 [in Russian].
23. Adler, A., Araya-Polo, M., & Poggio, T. (2019). Deep Recurrent Architectures for Seismic Tomography. *81st EAGE Conference & Exhibition*. Retrieved from <https://arxiv.org/ftp/arxiv/papers/1908/1908.07824.pdf>.
24. Qian, K. A., Guo, D., Xiang, X., & Qiao, Y. (2021). Two-Step Method for Prediction of Fractured Tight Sandstone Reservoir in Northeast Sichuan Basin. 82nd EAGE Annual Conference Exhibition. DOI 10.3997/2214-4609.202112900.
25. Fisher, W., Camp, T., & Krzhizhanovskaya, V. (2016). Anomaly Detection in Earth Dam and Levee Passive Seismic Data Using Support Vector Machines and Automatic Feature Selection. *Journal of Computational Science*. DOI 10.1016/j.jocs.2016.11.016.
26. Akinina, N. V., Akinin, M. V., Sokolova, A. V., Nikiforov, M. B., & Taganov, A. I. (2016). Autoencoder: an approach to reducing the dimension of a vector space with control over my loss of information. *Izvestiya TulGU. Tekhnicheskie nauki [Izvestia TulSU. Technical sciences]*, No. 9. Retrieved from <https://cyberleninka.ru/article/n/avtoenkoder-podhod-k-ponizheniyu-razmernosti-vektornogo-prostranstva-s-kontroliruemoy-poterey-informatsii/viewer> [in Russian].
27. Duc Bui Min, Hui Nguyen Ngoc, Lin Lai Thi, Hyu Nguyen Ba, Truong Nguyen Dinh, & Lam Nguyen Chong. (2017). Data compression. *Problemy Nauki [Problems of Science]*, No. 1(83). Retrieved from <https://cyberleninka.ru/article/n/szhatie-dannyh/viewer> [in Russian].
28. Safronov, D. A., Katser, Yu. D., & Zaitsev, K. S. (2022). Search for anomalies using autoencoders. *International Journal of Open Information Technologies*, No. 8. Retrieved from <https://cyberleninka.ru/article/n/poisk-anomaliy-s-pomoschyu-avtoenkoderov/viewer> [in Russian].
29. Namiot, D. E., & Ilyushin, E. A. (2022). Generating Models in Machine Learning. *International Journal of Open Information Technologies*, No. 7. Retrieved from <https://cyberleninka.ru/article/n/porozhdayuschie-modeli-v-mashinnom-obuchenii/viewer> [in Russian].

### Author details

Ivan Y. Stepanov – Assistant, Department of Digital Technologies, Institute of Digit.

Received 06.07.2023

© I. Y. Stepanov, 2024