

МРНТИ 38.27.23:50.53.17

А. Шарапатов, \*А. Садуов, Н. Асирбек  
 КазННТУ им. К.И. Сатпаева (г. Алматы, Казахстан)

## СРАВНИТЕЛЬНЫЙ АНАЛИЗ ВОЗМОЖНОСТЕЙ АЛГОРИТМОВ МАШИННОГО И ГЛУБОКОГО ОБУЧЕНИЯ В ГЕОЛОГИИ

**Аннотация.** Внедрение методов искусственного интеллекта – машинного и глубокого обучения, в решение задач геологии представляет собой существенный прорыв в технологии решения геопрогнозных задач. Анализ и сравнение эффективности различных алгоритмов машинного и глубокого обучения позволяет дать оценку их способностям адаптироваться к разным геологическим сценариям/заданиям, определить возможности технологии в интерпретации геологических данных и оптимизации объемов работ. В качестве объектов анализа и элементов изучения привлечены различные типы геоданных, алгоритмов машинного и глубокого обучения, геологических задач. Проведен сравнительный анализ производительности, точности алгоритмов в разных геологических контекстах. В анализе и обобщении возможностей алгоритмов искусственного интеллекта использован метод сравнения. Результаты показали актуальность их использования в обработке и интерпретации геоданных.

**Ключевые слова:** машинное и глубокое обучение, сверточные и рекуррентные нейронные сети, обработка естественного языка, прогнозирование геологических событий, интеграция данных, автоматизация геологической интерпретации, точность анализа.

### Геологиядағы машиналық және терең оқыту алгоритмдерінің мүмкіндіктерін салыстырмалы талдау

**Аннотация.** Геология мәселелерін шешуге жасанды интеллект әдістерін – машиналық және терең оқытуды енгізу, геоболжау тапсырмаларын орындау технологиясындағы елеулі серпіліс болып табылады. Машиналық және терең оқытудың әртүрлі алгоритмдерінің тиімділігін талдау және салыстыру олардың әртүрлі геологиялық сценарийлерге/тапсырмаларға бейімделу мүмкіндіктерін бағалауға, геологиялық деректерді түсіндіруде және жұмыс көлемін онтайландыруда технологияның ықпалын анықтауға мүмкіндік береді. Талдау объектілері және зерттеу элементтері ретінде геодеректердің түрлері, машиналық және терең оқыту алгоритмдері, геологиялық тапсырмалар қамтылды. Әртүрлі геологиялық контексттердегі алгоритмдердің өнімділігі мен дәлдігіне салыстырмалы талдау жүргізілді. Жасанды интеллект алгоритмдерінің мүмкіндіктерін сараптау мен топтамалауда салыстыру әдісі қолданылды. Нәтижелер оларды геодеректерді өңдеу мен түсіндіруде қолданудың өзектілігін көрсетті.

**Түйінді сөздер:** машиналық және терең оқыту, конволюциялық және қайталанатын нейрондық желілер, табиғи тілді өңдеу, геологиялық оқиғаларды болжау, деректерді біріктіру, геологиялық интерпретацияның автоматтандыру, сараптау дәлдігі.

### Comparative analysis of the capabilities of machine learning and deep learning algorithms in geology

**Abstract.** The implementation of artificial intelligence methods – machine and deep learning – in solving geological tasks represents a significant breakthrough in the technology of solving geopredictive problems. Analysis and comparison of the effectiveness of various machine and deep learning algorithms allow us to assess their ability to adapt to different geological scenarios/tasks, determine the potential of technology in the interpretation of geological data, and optimize the volume of work. Various types of geodata, algorithms of machine and deep learning, and geological tasks were used as objects of analysis and elements of study. A comparative analysis of the performance and accuracy of algorithms in different geological contexts was conducted. In the analysis and generalization of the capabilities of artificial intelligence algorithms, the comparison method was used. The results showed the relevance of their use in processing and interpreting geodata.

**Key words:** machine and deep learning, convolutional and recurrent neural networks, natural language processing, geological event forecasting, data integration, automation of geological interpretation, accuracy of analysis results.

### Введение

Системное и повсеместное изучение земной коры, анализ ее структурных особенностей, поиск полезных ископаемых – основы геологических исследований, призванных не только обогатить наше понимание природы, но и обеспечить устойчивое развитие общества. С появлением искусственного интеллекта (ИИ – *Artificial intelligence, AI*) – алгоритмов машинного и глубокого обучения, специалисты геонаук обрели мощный инструмент для анализа и интерпретации сложных данных о Земле. Алгоритмы, основанные на искусственных нейронных сетях и статистических методах, демонстрируют потенциал перевернуть традиционный способ анализа. Они ускоряют и углубляют понимание процессов, происходящих в недрах Земли.

Сложность геологических явлений, их нелинейность и многопараметричность часто ограничивают возможности классических методов исследования и процессы изучения объектов становятся трудоемкими. Алгоритмы машинного и глубокого обучения предоставляют возможность автоматизированной обработки огромных массивов данных и выявления невидимых на первый взгляд закономерностей. Применение таких алгоритмов в геонауках может значительно ускорить процесс обнаружения месторождений полезных ископаемых, точнее определить риски геологических катастроф и так далее; в целом – оптимизировать объем работ и повысить эффективность исследований объектов и явлений [1].

Цель данного обзора заключается в систематизации применения алгоритмов машинного и глубокого обучения в геологии. Основные задачи включают в себя анализ различных типов геологических данных, исследование их применимости к разнообразным геологическим задачам, оценку эффективности используемых алгоритмов, а также проведение сравнительного анализа и выявление преимуществ и ограничений каждого метода. В конечном итоге, данное исследование стремится обеспечить более подробное понимание влияния алгоритмов машинного и глубокого обучения на получение геологических результатов с использованием современных технологий и их перспективы для совершенствования.

Развитие применения алгоритмов машинного и глубокого обучения в геологии и других отраслях в целом находится в тесной взаимосвязи с эволюцией информационных технологий и ростом доступности вычислительных ресурсов. Начавшись в последние десятилетия XX века, направление получило мощный импульс благодаря прогрессу в области искусственных нейронных сетей и алгоритмов глубокого обучения.

**Пионерские шаги.** Первые попытки автоматизации анализа геологических данных относятся к 1960-70-м годам, когда появились первые компьютерные системы для обработки сейсмических данных. Однако, ограниченные вычислительные мощности и недостаточно развитые алгоритмы не позволяли достичь выдающихся результатов.

*Рост вычислительных возможностей.* С развитием вычислительных технологий в 1990-2000-е годы начали появляться более сложные алгоритмы, позволяющие обрабатывать и анализировать более разнообразные типы геологических данных. Это привело к повышению точности интерпретации и определения характеристик глубинных структур.

*Возрождение с глубоким обучением.* С появлением глубокого обучения в середине 2010-х годов произошел настоящий прорыв. Рекуррентные нейронные сети, сверточные нейронные сети и другие алгоритмы показали способность выявлять сложные геологические закономерности, что сделало анализ данных более точным и прогностическим.

*Современные достижения.* Сегодня алгоритмы машинного и глубокого обучения успешно применяются в разных направлениях геонаук: для картирования геологических структур, прогнозирования сейсмических и других геофизических событий [2], классификации минералов и оценки рисков геологических опасностей. Эти достижения способствуют не только улучшению качества исследований, но и более эффективному использованию природных ресурсов и оптимизации объемов работ.

### Методы и методология создания ИИ

Для успешной реализации возможностей алгоритмов машинного и глубокого обучения в геологии требуется обзор и анализ их основных характеристик. Они заложены в теории и концепциях их разработки [3]. Сравнительный анализ и оценка результатов применения различных алгоритмов обеспечивает понимание, выбор и эффективность использования подмножеств ИИ.

Обзор методов, использованных в исследованиях на данную тему, охватывает их широкий спектр, которые направлены на анализ разнообразных типов геологических данных. Важно отметить, что методы обычно выбираются с учетом специфики задачи и типов/форматов данных.

1. *Машинное обучение (Machine Learning, ML).* Алгоритм ML работает со структурированными данными. Например, для выделения в геологическом разрезе песков по фракциям в базе ML они должны иметь коды по размерам зерен (мелко-, средне-, крупнозернистые).

Практические решение геологических задач выполняется с использованием таких функций, как линейная регрессия (прогнозирование значений одной переменной на основе значений другой), деревья решений (классификация и регрессия на основе иерархических правил принятия решения), k-ближайших соседей (классификация объектов на основе их схожести с другими объектами), метод опорных векторов (классификация и регрессия с использованием гиперплоскости, разделяющей объекты разных классов) и т. д.

2. *Искусственные нейронные сети (ANN/Deep Learning, DL).* Основанная на биологических нейронных сетях, теория ANN обуславливает создание алгоритмов, способных обрабатывать и анализировать информацию аналогично мозгу человека. Глубокие нейронные сети с множеством слоев (глубокое обучение) позволяют извлекать высокоуровневые абстракции из данных. Как

пример можно привести задачу изучения геологических структур на основе данных дистанционного зондирования Земли (ДЗЗ). В этом случае глубокое обучение может быть использовано для анализа спектральных, пространственных и временных характеристик изображений, чтобы выделить определенные геологические структуры, такие как геосинклинальные складки, разломы и другие. Это позволяет геологам и другим специалистам более точно и эффективно интерпретировать данные и принимать обоснованные решения при поиске минеральных ресурсов, оценке геологических рисков и выполнении подобных задач.

Решение прикладных задач возможно с использованием функции активации (сигмоида, гиперболический тангенс, линейный выпрямитель), функции потерь (средне-квадратичная ошибка, кросс-энтропия), оптимизаторов (стохастический-градиентный спуск, оптимизатор Адам – *Adaptive Moment Estimation*) [4].

3. *Сверточные нейронные сети (CNN/Deep Learning, DL).* Основная идея заключается в использовании специализированных слоев для автоматического извлечения иерархических признаков из входных геоданных, что делает их эффективными для анализа изображений и пространственных данных. Применяются для анализа геологических изображений, таких как снимки спутников и сейсмические секции.

Как инструмент ИИ используются специализированные сверточные полносвязные слои, функции активации, пулинг. Они автоматически извлекают важные признаки из данных.

4. *Рекуррентные нейронные сети (RNN/Deep Learning, DL).* Ключевой концепцией является наличие обратной связи, что делает их подходящими для анализа последовательных данных, таких как временные ряды и тексты. Применяются, например, для прогнозирования сейсмических событий или изменений в подземных водах.

Решение прикладных задач возможно с использованием функции активации, функции потерь, рекуррентных и выходных слоев [5].

5. *Генеративные адверсарные сети (GAN).* Используются для генерации синтетических геологических данных, что может помочь улучшить обучение моделей при нехватке больших наборов данных. Например, для синтеза геофизических изображений (временной и другие разрезы). С помощью GAN можно генерировать синтетические сейсмические данные, что позволяет улучшить моделирование подземных структур и прогнозирование наличия полезных ископаемых. Также могут быть использованы для синтеза изображений образцов пород, которые могут быть аналогичны реальным образцам. Образцы пород (керна) извлекаются в результате бурения и позволяют моделировать различные геологические процессы – эрозия, осадкообразование и другие. Результаты могут помочь при прогнозе месторождений, в понимании эволюции геологических формаций [6].

Для решения задач используются алгоритмы генератора для синтеза новых данных; дискриминатора для классификации данных на реальные и синтетические; функции потерь и оптимизаторов.

6. *Обработка естественного языка (NLP)*. Применяется для анализа текстовых данных, таких как геологические отчеты, и выявления ключевых слов и фраз. NLP может использоваться для автоматического извлечения специфической информации о типах пород, минералов и геологических структур, классификации отчетов по категориям, анализа результатов для оценки успешности исследований, генерации текстовых отчетов на основе введенных данных, а также семантического анализа для выявления взаимосвязей между геологическими терминами и концепциями.

Анализ геоданных указанных типов возможен с использованием таких инструментов как токенизатор, который используется для разбиения текста на отдельные слова или фразы (токены). В последующем анализ или векторизатор преобразует токены в числовые векторы, которые могут быть использованы для анализа текста. Также используются: модель Word Embedding для преобразования слов в векторы в многомерном пространстве таким образом, что слова с похожим смыслом располагаются близко друг к другу; модель классификации текста (Text Classification Model) по определенным категориям на основе их содержания; модель анализа настроений (Sentiment Analysis Model) для определения «настроения» текста, например, положительное или отрицательное.

При решении задач геологии и смежных наук практическая реализация теоретических положений и возможностей ИИ проводится с использованием *ключевых понятий и терминов*:

1. *Обучение с учителем и без учителя*. В обучении с учителем модель обучается на основе пар входных данных и соответствующих им выходных меток. В обучении без учителя модель выявляет закономерности в данных без заранее известных выходных меток.

2. *Функция потерь*. Это метрика, используемая для оценки различия между предсказаниями модели и фактическими значениями. Цель обучения – минимизировать эту функцию.

3. *Гиперпараметры*. Параметры модели, которые настраиваются до начала обучения и влияют на процесс обучения и качество модели.

4. *Предварительное обучение*. Процесс обучения модели на большом объеме данных для извлечения общих признаков, которые затем могут быть использованы для специфических задач.

5. *Аугментация данных*. Методика, заключающаяся в создании новых вариантов данных путем применения различных трансформаций (повороты, обрезки и т. д.) к оригинальным данным. Это позволяет улучшить обобщающую способность модели [7].

Этапы анализа данных и получения результатов можно описать в следующей последовательности: а) подготовка данных: исходные геологические данные подвергаются предварительной обработке, включающей шумоподавление, нормализацию и аугментацию для улучшения качества и разнообразия данных; б) выбор алгоритмов: в зависимости от типа данных и поставленных задач, выбираются наиболее подходящие алгоритмы машинного и глубокого обучения, такие как CNN для изображений или RNN для временных рядов; в) обучение модели: модель

обучается на подготовленных данных с использованием обучающего набора и настройкой гиперпараметров и оптимизация функции потерь; г) валидация и тестирование: обученная модель проверяется на отложенных данных для оценки её производительности и обобщающей способности; д) анализ результатов: полученные результаты оцениваются с использованием соответствующих метрик (точность, F1-мера, ROC-AUC и др.), что позволяет сравнивать эффективность различных методов [8-9].

Используя данную методологию, проводятся исследования, направленные на раскрытие потенциала алгоритмов машинного и глубокого обучения и выявление более рациональных и эффективных подходов к анализу разнообразных геологических данных.

### Современное состояние, тренды и перспективы

На сегодняшний день применение алгоритмов машинного и глубокого обучения в геологии является активно развивающейся областью с множеством перспективных направлений:

1. Улучшение точности интерпретации: модели машинного и глубокого обучения демонстрируют впечатляющие результаты в области точной классификации и интерпретации геологических данных, таких как сейсмические секции и геохимические данные.

2. Создание синтетических данных: генеративные модели, такие как GAN, позволяют создавать синтетические геологические данные, что полезно при недостатке реальных данных и позволяет улучшить обучение моделей.

3. Расширение геологических знаний: применение алгоритмов позволяет выявить скрытые закономерности в данных и дать новые инсайты, способствуя расширению наших познаний о структурах Земли.

Развитие перечисленных направлений возможно при обеспечении:

– интеграции данных и многомодального анализа: тенденция к использованию разнородных геоданных, таких как геолого-геофизические и геохимические наблюдения, изображения и текстовые отчеты для обеспечения более полного и точного анализа;

– автоматизации интерпретации и самообучения: развитие моделей, способных автоматически интерпретировать разнообразные типы данных, уменьшая человеческий фактор и повышая производительность (идентификация минералов – модели машинного обучения могут классифицировать минералы на основе спектральных данных, полученных с помощью ДЗЗ, что важно для геологической эксплорации);

– преодоления ограничений обучения с малым количеством данных: разработка методов, позволяющих эффективно обучать модели на небольших наборах данных;

– обработки и анализа больших данных: рост доступности больших объемов данных требует разработки эффективных методов и алгоритмов для их обработки и анализа. В качестве примера можно привести анализ сейсмических данных (алгоритмы глубокого обучения имеют возможность анализировать сейсмические секции для определения структур в Земле, что помогает при поисках месторождений нефти и газа);

– интеграции экспертных знаний: внедрение экспертных знаний специалистов геонаук (геологов, геофизиков, геохимиков и других) в алгоритмы обучения, позволяя создать гибридные модели, объединяющие данные и опыт исследователей. Например, при прогнозировании геологических опасностей – алгоритмы могут анализировать данные о землетрясениях, вулканических извержениях и других геологических событиях для прогнозирования потенциальных опасностей;

– улучшения интерпретируемости: создание методов, позволяющих более точно понимать, каким образом модели выполняют свои прогнозы;

– усовершенствования генеративных моделей: дальнейшее развитие GAN и подобных методов для создания синтетических геологических данных и расширения набора данных.

Общее направление развития ИИ при решении геопрогнозных задач заключается в постоянном стремлении улучшить точность, автоматизировать процессы анализа и раскрыть новые геологические знания [8].

*Совершенствование методов и использование практических приложений ИИ в геологии могут обеспечить ряд преимуществ по сравнению с традиционными технологиями. К ним можно отнести:*

1. Ускорение исследований: использование алгоритмов и автоматизация процессов анализа данных позволят гораздо быстрее обрабатывать и интерпретировать геологические данные, сократить время поиска месторождений полезных ископаемых, что важно для экономии ресурсов;

2. Точность и надежность результатов: модели могут обнаруживать закономерности, которые не всегда выявляются с помощью анализа и обобщения данных специалистом-экспертом, что повышает точность интерпретации данных;

3. Минимизация рисков: прогнозирование геологических событий и опасностей позволяет принимать меры предосторожности и минимизировать потенциальные риски (землетрясения, извержения вулканов и другие геологические события);

4. Оптимизация разработки месторождений: алгоритмы могут помочь оптимизировать планы добычи и использования ресурсов, что повышает эффективность процессов добычи, снижает геологические риски;

5. Инновации в исследованиях: применение технологий ИИ позволяет открывать новые пути в геологических исследованиях и расширять границы познания о Земле;

6. Создание глобальных моделей: развитие универсальных моделей, способных работать с разнообразными типами данных и условиями;

7. Развитие геологической инфраструктуры: внедрение современных технологий ИИ может способствовать созданию новых методов и инструментов для геологических исследований [9].

Использование алгоритмов машинного и глубокого обучения в геонауках имеет множество примеров конкретных применений и практических преимуществ. Применение ИИ, адаптированного к задачам и форматам геоданных, способствует более точному анализу фактических материалов, оптимизации объемов работ, инновационному под-

ходу к изучению геологических процессов и, как результат, созданию новых знаний о Земле и ее недрах.

### **Обсуждение вызовов и проблем**

Они носят разный характер и отрицательно влияют на эффективность получения результатов с помощью ИИ:

1. Требование большого объема данных/недостаток геоданных: в геологии исследователи сталкиваются с отсутствием, неоднозначностью и недостаточной детальностью информации. Дополнительно надо отметить дороговизну сбора и технологии анализа, например, скважинных данных. Процесс охватывает проведение буровых работ с извлечением керна и разных лабораторных исследований проб на дорогостоящих оборудованных. Отсутствие таких сведений могут ограничивать эффективность обучения моделей.

2. Сложность настройки гиперпараметров: выбор правильных гиперпараметров моделей может быть сложным и требовать экспериментов.

3. Интерпретируемость моделей: глубокие нейронные сети могут быть сложными (без видимых причинно-следственных связей в результатах интерпретации данных), что затрудняет понимание принимаемых ими решений. То есть, модели могут допускать ошибки, и важно понимать, как они принимают решения и насколько этот процесс надежен.

4. Недостаток экспертных данных специалистов: валидация моделей требует наличие экспертных данных для сравнения с результатами прогноза моделей. Их недостаток может ограничивать процесс.

5. Обобщение на новые данные: модели могут успешно работать на существующих данных, но, не всегда справляются с новыми, неизвестными данными.

6. Отсутствие универсальных моделей, подходящих для всех типов геологических данных и задач.

7. Этические вопросы: наличие больших объемов геоданных при использовании ИИ может вызвать вопросы этического характера по соблюдению их конфиденциальности (исключение недобросовестного использования сведений), равного доступа к ним всех заинтересованных сторон (например, недропользователей, геоэкологов и населения) [10-11].

Таким образом, хотя применение алгоритмов машинного и глубокого обучения в геологии имеет множество преимуществ, существуют и вызовы, которые требуют дополнительных исследований и разработок для их преодоления.

### **Заключение и выводы**

Обзор и анализ опубликованных результатов исследований в области разработки и применения технологий ИИ позволили обобщить и оценить его современное состояние и перспективы развития:

1. Применение алгоритмов ИИ в геологии и геонауках в целом активно развивается;

2. Применение алгоритмов машинного и глубокого обучения позволяет значительно улучшить работу с геоданными, начиная от обработки, интерпретации геоданных и заканчивая прогнозированием месторождений полезных ископаемых и опасных геологических событий;

3. Развитие глубокого обучения и наличие больших объемов геоданных создают новые возможности для анализа их разных типов, таких как геолого-геофизические (аэрокосмические, наземные и скважинные) и геохимические данные, результаты лабораторного изучения образцов пород/керна и текстовые материалы;

4. Однако существуют вызовы, такие как ограниченность данных и необходимость преодоления недостатка

экспертных знаний, сложности в интерпретации моделей;

5. Будущее использования ИИ может внести весомый вклад в создании универсальных моделей для анализа различных типов геоданных, точности прогнозирования геологических событий, улучшении управления природными ресурсами, также принести новые знания о Земле в целом.

#### СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ

1. Kshirsagar A., Sanghavi P. Прогнозирование температуры подземных слоев на месторождениях геотермальной энергии, нефти и газа с использованием машинного обучения. // Труды 47-го семинара по инженерии геотермальных резервуаров. – 2022. – С. 7-9 (на английском языке)
2. Шарапатов А. О вариациях геомагнитного поля. // Известия Национальной академии наук Республики Казахстан. Серия геологии и технических наук. – 2014. – №6(408). – С. 35-40 (на русском языке)
3. Guo Y., Zhang S., Fu C., Yang Y. Картографирование перспективности минеральных ресурсов с использованием методов машинного обучения в районе Хэцзо-Мэйву, провинция Ганьсу. // Труды SPIE. – 2023. – С.72-83 (на английском языке)
4. Tut Naklidir F.S., Naklidir M. Прогнозирование температур в резервуарах с использованием гидрогеохимических данных, геотермальные системы Западной Анатолии (Турция): подход на основе машинного обучения. // Научные исследования природных ресурсов. – 2019. – №28(5). – С. 24-28 (на английском языке)
5. Xi C., Nan M., Hu X., Liu B., He K., Luo G., Cao X. Эффективность стратегии выборки на основе метода Ньюмарка для картографирования подверженности косейсмическим оползням с использованием глубокого обучения, машины опорных векторов и логистической регрессии. // Бюллетень инженерной геологии и окружающей среды. – 2022. – С. 93-97 (на английском языке)
6. Карамурзаева А. Б., Есполова Н. И., Шарапатов А. Литофациальный анализ юрских комплексов бозащинского свода. // Горный журнал Казахстан. – 2023. – №7(219). – С. 8-13 (на русском языке)
7. Chen Y., Zhao L., Pan J., Li C., Xu M., Li K., Zhang F., Geng J. Характеристика глубоких карбонатных резервуаров с использованием многомерных сейсмических атрибутов на основе машинного обучения с физическими ограничениями. // Журнал геофизики и инженерии. – 2021. – №18(5). – С. 62-67 (на английском языке)
8. Priezzhev I., Danko D., Strecker U. Новая эра нейронных сетей Колмогорова полной функции KNN: высокоточные прогнозы резервуаров через оценку свойств ядра, каротажа, карты и сеймики. // Материалы конференции Society of Petroleum Engineers – Abu Dhabi International Petroleum Exhibition and Conference, ADIP 2021. – Абу-Даби. 15-18 ноября 2021 г. (на английском языке)
9. Бурков А. Машинное обучение без лишних слов. // Санкт-Петербург: Питер, 2020. – С. 192 (на русском языке)
10. Жилов Р.А. Применение нейронных сетей при кластеризации данных. // Известия Кабардино-Балкарского научного центра РАН. – 2021. – №1(99). – С. 15-19 (на русском языке).
11. Bryushina D.S., Spirin A.A., Priezzhev I.I., Khaydarov A.S., Khisamutdinov I.I. Опыт применения нейронной сети Колмогорова для прогнозирования карт эффективной мощности и объемной модели клиноформного резервуара в Западной Сибири. // Нефтяное хозяйство. – 2021. – №12. – С. 11-15 (на английском языке)

#### ПАЙДАЛАНЫЛҒАН ӘДБИЕТТЕР ТІЗІМІ

1. Kshirsagar A., Sanghavi P. Геотермалдық, мұнай және газ ұңғымаларының тереңдік температурасын машиналық оқыту арқылы болжау // Геотермалдық қорлар инженериясының 47-ші жұмыс тобының еңбектері. – 2022. – Б. 7-9 (ағылшын тілінде)
2. Шарапатов А. Геомагниттік өрістің өзгеруі туралы. // Қазақстан Республикасының Ұлттық Ғылым Академиясының Хабарлары. Геология және техникалық ғылымдар сериясы. – 2014. – №6(408). – Б. 35-40 (орыс тілінде)
3. Guo Y., Zhang S., Fu C., Yang Y. Ганьсу провинциясының Хэцзо-Мэйву ауданында машиналық оқыту әдістерін қолдана отырып, минералдық ресурстарды картографиялау: SPIE жинағының жүйелі зерттеуі. – 2023. – Б. 72-83 (ағылшын тілінде)
4. Tut Naklidir F.S., Naklidir M. Батыс Анатолияның геотермалдық жүйелеріндегі резервуарлардың температурасын гидрогеохимиялық деректерді пайдалана отырып болжау: машиналық оқыту әдісі. // Табиғи ресурстарды зерттеу. – 2019. – №28(5). – Б. 24-28 (ағылшын тілінде)

5. Xi C., Han M., Hu X., Liu B., He K., Luo G., Cao X. Косейсмалық жыртуларға сезімталдық картасын жасау үшін Ньюмарк әдісін қолдану тиімділігі: терең оқыту, векторлық машина және логистикалық регрессия. // Инженерлік геология және қоршаған орта бюллетені. – 2022. – Б. 93-97 (ағылшын тілінде)
6. Карамурзаева А.Б., Есполова Н.И., Шарапатов А. Бозащы дөңесінің юра кешендерін литофациалық талдау. // Қазақстанның кен журналы – 2023. – №7(219). – Б. 8-13 (орыс тілінде)
7. Chen Y., Zhao L., Pan J., Li C., Xu M., Li K., Zhang F., Geng J. Физикалық шектеулермен машиналық оқыту арқылы көміртекті резервуарлардың тереңдік сипаттамасын жасау. // Геофизика және инженерия журналы. – 2021. – №18(5). – Б. 62-67 (ағылшын тілінде)
8. Priezzhev I., Danko D., Strecker U. Колмогоровтың жаңа дәуірдегі толық функционалды KNN нейрондық желісі: жоғары дәлдіктегі қор резервуарларын болжауға, ядро, ұңғыма журналы, карта және сейсмикалық қасиеттерді бағалау. // Society of Petroleum Engineers – Abu Dhabi International Petroleum Exhibition and Conference, ADIP 2021 конференциясының материалдары. – Абу-Даби, 2021 жылғы 15-18 қараша (ағылшын тілінде)
9. Бурков А. Артық сөзсіз машиналық оқыту. // Санкт-Петербург: Питер, 2020. – Б. 192 (орыс тілінде)
10. Жилов Р.А. Деректерді кластерлеу кезінде нейрондық желілерді қолдану. // Қабарды-Балқар ғылыми орталығының хабарландырулары РАН. – 2021. – №1(99). – Б. 15-19 (орыс тілінде)
11. Bryushina D.S., Spirin A.A., Priezzhev I.I., Khaydarov A.S., Khisamutdinov I.I. Колмогоровтың картографиялық нейрондық желісін Батыс Сібірдегі клиноформдық резервуардың тиімді қалыңдығының карталарын және көлемдік моделін болжауға қолдану тәжірибесі. // Мұнай өнеркәсібі. – 2021. – №12. – Б. 11-15 (ағылшын тілінде)

## REFERENCES

1. Kshirsagar A., Sanghavi P. Geothermal, oil and gas well subsurface temperature prediction employing machine learning // Proceedings of the 47th Workshop on Geothermal Reservoir Engineering – 2022. – P. 7-9 (in English)
2. Sharapatov A. O variaciyah geomagnitnogo polya [On variations of the geomagnetic field]. // Izvestiya Nacional'nyj akademii nauk Respubliki Kazakhstan. Seriya geologii i tekhnicheskikh nauk = Proceedings of the National Academy of Sciences of the Republic of Kazakhstan. Series of Geology and Technical Sciences. – 2014. – №6(408). – P. 35-40 (in Russian)
3. Guo Y., Zhang S., Fu C., Yang Y. GIS-based mineral prospectivity mapping: a systematic study on machine learning at Hezuo-Meiwu District, Gansu Province. // Proceedings of SPIE. – 2023. – P. 72-83 (in English)
4. Tut Haklıdır F.S., Haklıdır M. Prediction of Reservoir Temperatures Using Hydrogeochemical Data, Western Anatolia Geothermal Systems (Turkey): A Machine Learning Approach. // Natural Resources Research. – 2019. – №28(5). – P. 24-28 (in English)
5. Xi C., Han M., Hu X., Liu B., He K., Luo G., Cao X. Effectiveness of Newmark-based sampling strategy for coseismic landslide susceptibility mapping using deep learning, support vector machine, and logistic regression. // Bulletin of Engineering Geology and the Environment. – 2022. – P. 93-97 (in English)
6. Karamurzaeva A.B., Espolova N.I., Sharapatov A. Litofacial'nyj analiz yurskih kompleksov bozashchinskogo svoda [Lithofacial analysis of Jurassic complexes of the Bozashchinsky vault]. // Gornyj zhurnal Kazahstana = Mining Journal of Kazakhstan. – 2023. – №7(219). – P. 8-13 (in Russian)
7. Chen Y., Zhao L., Pan J., Li C., Xu M., Li K., Zhang F., Geng J. Deep carbonate reservoir characterisation using multi-seismic attributes via machine learning with physical constraints. // Journal of Geophysics and Engineering. – 2021. – №18(5). – P. 62-67 (in English)
8. Priezzhev I., Danko D., Strecker U. New-Age Kolmogorov Full-Function Neural Network KNN Offers High-Fidelity Reservoir Predictions via Estimation of Core, Well Log, Map and Seismic Properties. // Proceedings of the Society of Petroleum Engineers – Abu Dhabi International Petroleum Exhibition and Conference, ADIP 2021. – Abu Dhabi. – November 15-18 (in English)
9. Burkov A. Mashinnoe obuchenie bez lishnih slov [Machine learning without unnecessary words]. // Sankt-Peterburg = Piter. – 2020. – P. 192 (in Russian)
10. Zhilov R.A. Primeneniye neyronnyh setej pri klasterizacii dannyh [Application of neural networks in data clustering]. // Izvestiya Kabardino-Balkarskogo nauchnogo centra RAN = Proceedings of the Kabardino-Balkarian Scientific Center of the Russian Academy of Sciences. – 2021. – №1(99). – P. 15-19 (in Russian)
11. Bryushina D.S., Spirin A.A., Priezzhev I.I., Khaydarov A.S., Khisamutdinov I.I. Opyt primeneniya neyronnoy seti Kolmogorova dlya prognozirovaniya kart effektivnoy moshchnosti i obyemnoy modeli

*klinoformnogo rezervuara v Zapadnoy Sibiri [Experience in using a Kolmogorov neural network to predict effective power maps and a volumetric model of a clinoform reservoir in Western Siberia]. // Neftyanoe Khozyaystvo = Oil Industry. – 2021. – Vol. 12. – P. 11-15 (in Russian)*

**Сведения об авторах:**

**Шарапатов А.**, кандидат геолого-минералогических наук, ассоциированный профессор кафедры Геофизики КазНУ им. К.И. Сатпаева (г. Алматы, Казахстан), [a.sharapatov@satbayev.university](mailto:a.sharapatov@satbayev.university); <https://orcid.org/0000-0003-2578-3817>

**Садуов А.**, докторант кафедры Геофизики КазНУ им. К.И. Сатпаева (г. Алматы, Казахстан), [a.saduov@satbayev.university](mailto:a.saduov@satbayev.university); <https://orcid.org/0000-0003-1501-7772>

**Асирбек Н.**, магистр технических наук, старший преподаватель кафедры Геофизики КазНУ им. К.И. Сатпаева (г. Алматы, Казахстан), [n.assirbek@satbayev.university](mailto:n.assirbek@satbayev.university); <https://orcid.org/0000-0001-9803-4011>

**Авторлар туралы мәліметтер:**

**Шарапатов Ә.**, геология-минералогия ғылымдарының кандидаты, Сәтбаев Университеті Геофизика кафедрасының қауымдастық профессоры (Алматы қ., Қазақстан)

**Садуов Ә.**, докторант, Сәтбаев Университетінің Геофизика кафедрасы (Алматы қ., Қазақстан)

**Әсірбек Н.**, техника ғылымдарының магистрі, Сәтбаев Университеті Геофизика кафедрасының аға оқытушысы (Алматы қ., Қазақстан)

**Information about the authors:**

**Sharapatov A.**, Candidate of Geological and Mineralogical Sciences, Associate Professor of the Department of Geophysics of Satbayev University (Almaty, Kazakhstan)

**Saduov A.**, PhD student of the Department of Geophysics of Satbayev University (Almaty, Kazakhstan)

**Assirbek N.**, Master of technical sciences, Senior-lecturer of the Department of Geophysics of Satbayev University (Almaty, Kazakhstan)

СПТО  
КРАНЫ



**3-5 апреля  
2024 г.**

**ЦВК ЭКСПОЦЕНТР,  
павильон № 8**

МЕЖДУНАРОДНАЯ СПЕЦИАЛИЗИРОВАННАЯ ВЫСТАВКА

**СПТОКРАНЫ**

СПЕЦТЕХНИКА И ПОДЪЕМНО-ТРАНСПОРТНОЕ ОБОРУДОВАНИЕ