

DOI: 10.25558/VOSTNII.2024.58.64.004

УДК 528.88:528.8.044.2

© Т. А. Киряева, С. Е. Попов, В. П. Потапов, 2024

Т.А. КИРЯЕВА

д-р техн. наук,
старший научный сотрудник
Институт горного дела СО РАН, г. Новосибирск
e-mail: coalmetan@mail.ru



С.Е. ПОПОВ

канд. техн. наук,
старший научный сотрудник
Федеральный исследовательский центр
информационных и вычислительных технологий,
г. Кемерово
e-mail: ogidog@yandex.ru



В. П. ПОТАПОВ

д-р техн. наук, проф., главный научный сотрудник
Федеральный исследовательский центр
информационных и вычислительных технологий,
г. Кемерово
Институт горного дела СО РАН, г. Новосибирск
e-mail: vadimptpv@gmail.com



НЕЙРОННЫЕ СЕТИ В ЗАДАЧАХ ГЕОМЕХАНИКИ, ВОЗМОЖНОСТИ ПРИМЕНЕНИЯ, МЕТОДЫ ОЦЕНКИ

В работе рассматриваются некоторые особенности применения методов искусственного интеллекта (ИИ) в задачах геомеханики. Авторы в своей работе выделяют как наиболее часто используемый метод искусственного интеллекта-нейронные сети [1] и анализируют возможности их применения. Приводятся практические аспекты использования аппарата нейронных сетей для различных моделей геомеханики, использующих вычислительные, информационно-аналитические методы, обработку больших данных, описания свойств массива горных пород, новых методов получения знаний. Для каждого класса моделей рассматриваются возможности нейронных сетей различных архитектур, которые позволят с новой стороны взглянуть на традиционные способы описания горного массива, подвергаемого техногенному воздействию. С учетом того, что нейронные сети работают по принципу «черного ящика», для адекватности их применения предлагается использование методов оценки их работы, основанные на объяснимости (Explainable) и интерпретируемости (Interpretability), которые, по мнению авторов, позволят повысить эффективность использования нейронных сетей для решения прикладных задач геомеханики. В работе рассматриваются некоторые задачи (детектирование систем трещин и расчет характеристик их полей, длинные временные ряды). Авторами отмечается большой потенциал нейронных сетей для разработки научных основ комплексной теории освоения месторождений.

Ключевые слова: МЕТОДЫ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА, НЕЙРОННЫЕ СЕТИ, ОБЪЯСНИМОСТЬ МОДЕЛЕЙ, ИНТЕРПРЕТИРУЕМОСТЬ МОДЕЛЕЙ, ПОЛЯ ТРЕЩИН, ИНФОРМАЦИОННО-АНАЛИТИЧЕСКИЕ МОДЕЛИ, LSTM СЕТИ, АНАЛИЗ ТРЕЩИН, АРХИТЕКТУРА НЕЙРОННОЙ СЕТИ, БОЛЬШИЕ ДАННЫЕ.

ВВЕДЕНИЕ

Ускоренное развитие систем Искусственного Интеллекта (ИИ), особенно в последние годы, приводит к пересмотру возможностей их использования в геомеханике. Например, в недавнем исследовании было показано, что ИИ могут быть использованы для моделирования поведения геоструктур при изменении нагрузок. Также было показано, что ИИ могут быть использованы для прогнозирования последствий изменения геомеханических параметров. В настоящей работе мы сделали попытку рассмотреть основные аспекты применения геоинформационных технологий, обеспечивающих сбор, хранение, обработку и анализ геомеханических данных и их интеграции с системами ИИ. Например, такие средства могут быть использованы для предсказания изменений в геомеханических системах и для оптимизации процессов планирования и проектирования горных работ.

ВОЗМОЖНОСТИ МЕТОДОВ ИИ ДЛЯ ГЕОМЕХАНИКИ

Рассмотрим возможности использования методов ИИ для вычислительных моделей геомеханики. Сегодня эти методы обеспечиваются множеством алгоритмов и программ, реализующих различные математические модели сплошной среды (например, различные модификации метода конечных элементов, граничные интегральные уравнения и т.д.). Множество их программных реализаций [2] существенно затрудняет выбор подходящего варианта для решения конкретных задач, и обычно исследователи прибегают к хорошо зарекомендовавшему себя программному обеспечению. Например, метод конечных элементов широко используется в области структурного анализа, а метод граничных элементов — в области акустики. Кроме того, сложность выбора подходящей реализации численного метода усугубляется тем, что одна и та же задача может быть решена с помощью различных программных средств.

Для этого случая применение методов ИИ позволяет не только выбрать наиболее

подходящую для решения задачи программу с учетом оптимального использования той или иной модели, но и дает возможность интегрировать модели, генерируя соответствующий программный код. При использовании комбинированных моделей для каждого этапа вычислений будет предоставляться метод, удовлетворяющий граничным и начальным условиям этапа. Например, интеграция моделей глубокого обучения и обучения с подкреплением может быть использована для оптимизации процесса вычислений в сложных средах. Кроме того, оптимальность использования той или иной модели может быть определена путем оценки точности прогнозов модели и стоимости ее реализации, используя методы ИИ.

В этой области уже появляются первые работы, поэтому предлагаемый подход имеет определенные перспективы. Прежде чем перейти к техническим аспектам, необходимо уточнить что такое Task Execution Engine. Это программный компонент, предназначенный для автоматизации, планирования и управления задачами или процессами с использованием больших языковых моделей (LLM) [3]. Эти задачи могут варьироваться от простой обработки данных до сложных бизнес-процессов. Механизмы выполнения задач играют неосценимую роль в сокращении ручного труда, обеспечении согласованности и повышении производительности. В последние годы LLM, такие как GPT-3, GPT-4 [4–5] и подобные им модели, привлекают к себе большое внимание благодаря своей способности генерировать человекоподобный текст и выполнять задачи понимания естественного языка. Использование LLM в механизме выполнения задач может привести к более интеллектуальной, контекстно-зависимой и гибкой автоматизации решений.

Методы ИИ удобно использовать при задании начальных и граничных условий, иллюстрируя некоторые аналогичные решения. Например, методы искусственного интеллекта можно использовать для выявления закономерностей в массивах данных, которые

могут быть использованы для обоснования решений. Кроме того, методы искусственного интеллекта могут использоваться для выявления корреляций между различными переменными и построения прогностических моделей. Это может быть полезно в различных контекстах, например, для прогнозирования поведения массива горных пород или предсказания результатов развития того или иного процесса.

Информационно-аналитические системы для задач геомеханики, основанные на методах ИИ, представляют собой совершенно новый класс средств обработки пространственной информации, позволяющий не только концентрировать знания об основных методах и моделях этой области, но и генерировать ответы на любые вопросы в рамках данной тематики. Например, методы на основе ИИ могут быть использованы для выявления закономерностей в больших массивах данных, которые используются для прогнозирования поведения геологических структур. Кроме того, эти системы могут быть использованы для разработки новых алгоритмов решения сложных задач геомеханики, таких как моделирование распространения сейсмических волн в неоднородных средах.

Также они могут быть применены для создания детальных трехмерных моделей недр в различных приложениях, например, для разведки нефти и газа. В основе разработки таких инструментов также лежат большие языковые модели LLM, которые, по сути, представляют собой предварительно обученную локальную модель, аналогичную широко известной системе искусственного интеллекта OpenAI GPT [6]. Эта модель обучается на подготовленных и структурированных определенным образом текстовых материалах, таких как предложения и слова, а затем генерирует ответы на вопросы, содержащиеся в этих материалах, используя алгоритмы машинного обучения, такие как контролируемое и неконтролируемое обучение.

Разрабатывая подобные системы, пользователь систематизирует имеющуюся у него пространственную информацию, которая

может быть не только текстовой или числовой, но и мультимодальной, включающую в себя графические или аудиофайлы. Данный подход позволит разрабатывать системы геомеханического мониторинга на принципиально новой гибкой платформе, работающей на привычном для пользователя языке. В отличие от баз, хранилищ и озер данных, в которых запросы достаточно жестко регламентированы и используются SQL-подобные языки [7], системы искусственного интеллекта могут генерировать ответы на произвольные запросы, в том числе на естественном языке, который слабо структурирован и может иметь любой размер запроса и ответа.

Следует отметить, что переобучение типовых моделей, особенно на русском языке, является достаточно сложной и ресурсоемкой задачей, требующей привлечения специалистов по ИИ, знакомых с подобными методами и моделями. Однако эти вложения впоследствии окупаются за счет универсальности и гибкости системы, позволяющей любому пользователю получить ответы на свои вопросы. Например, система может использовать машинное обучение для анализа и интерпретации данных и давать подробные ответы на произвольные запросы. Она также может использовать принципы обработки естественного языка для понимания контекста запроса и выдачи соответствующего ответа. При этом, системы ИИ могут использовать предиктивную аналитику для предвидения потребностей пользователей и предоставления персонализированных ответов, которые существенно уточнят знания в конкретной области (для нашего случая, в нелинейной геомеханике).

Обработка цифровых потоков пространственных данных, которые в большинстве случаев представляют собой многомерные временные ряды, требует специализированных средств ИИ, при этом также используются нейронные сети специальной архитектуры типа LSTM [8]. Эта аббревиатура для Long Short-Term Memory можно перевести как «Долговременная краткосрочная память». LSTM представляет собой специальную

разновидность рекуррентных нейронных сетей, способных обучаться на длинных последовательностях данных, сохраняя контекстную информацию.

В отличие от обычных рекуррентных сетей, LSTM сети содержат специальные ячейки памяти, позволяющие сохранять информацию о предыдущих входах на протяжении многих тактов. Это помогает LSTM моделям лучше обрабатывать долгосрочные зависимости в данных. Благодаря архитектуре с ячейками памяти, LSTM сети хорошо подходят для работы с естественным языком, речью, временными рядами и другими последовательными данными, где важны отдаленные связи и контекст. В задачах геомеханики, где важны сложные зависимости и взаимосвязи между различными параметрами, нейронные сети могут помочь в обработке и анализе многомерных временных рядов. Ниже приведены основные позиции применения нейронных сетей, включая LSTM, в следующих задачах.

1. Прогнозирование поведения грунта и деформаций в нем.

В данном случае LSTM нейронные сети могут быть использованы для анализа многомерных временных рядов, содержащих данные о нагрузке, деформациях грунта, погодных условиях и других факторах, влияющих на поведение грунта. На этапе обучения LSTM модель будет анализировать и улавливать зависимости между различными переменными и их взаимосвязи со временем. На основе исторических данных, модель сможет прогнозировать будущие деформации грунта при изменении условий нагрузки, что позволит принимать предупредительные меры и контролировать состояние геомеханической системы.

2. Определение оптимальных параметров конструкций и фундаментов.

Нейронные сети, включая LSTM, могут быть использованы для оптимизации параметров проектирования конструкций и фундаментов на основе анализа многомерных временных рядов и других данных о состоянии окружающей среды. В процессе обучения

модели будут выявляться оптимальные значения параметров, обеспечивающие наилучшую стабильность и безопасность конструкции или фундамента. Это позволит инженерам и проектировщикам принимать более обоснованные решения при создании новых конструкций или улучшении существующих.

3. Анализ данных геомеханического мониторинга.

LSTM нейронные сети могут быть применены для обработки данных, полученных от датчиков, установленных на объектах геомеханики. Датчики могут измерять различные параметры, такие как деформации, давление, температура и т.д., и эти данные могут представлять собой многомерные временные ряды. LSTM позволяют учитывать зависимости во времени, что поможет выявлять тенденции и изменения в поведении геомеханических систем, что особенно важно для мониторинга опасных участков или строительных объектов.

4. Диагностика и предотвращение аварий.

Нейронные сети, включая LSTM, могут быть использованы для создания системы диагностики и предотвращения аварийных ситуаций. Анализ данных мониторинга и исторических данных может помочь выявить предвестники возможных аварий, такие как необычные деформации или резкие изменения параметров. LSTM модели могут предсказывать потенциальные риски аварий и предоставлять оперативные рекомендации по предотвращению негативных последствий.

5. Моделирование нелинейных взаимодействий.

В задачах нелинейной геомеханики могут существовать сложные и неочевидные взаимодействия между различными параметрами и элементами системы. Нейронные сети, включая LSTM, позволяют создавать сложные математические модели, которые учитывают нелинейные зависимости во времени и пространстве. Такие модели могут предоставить более точные и реалистичные прогнозы поведения геомеханических систем,

что способствует улучшению процесса проектирования и контроля за поведением объектов.

Важно отметить, что для успешного применения нейронных сетей в задачах нелинейной геомеханики требуется обширный объем данных для обучения моделей. Качество данных и правильный выбор параметров обучения также являются ключевыми аспектами. Интерпретация результатов моделирования и проверка точности прогнозов также должны осуществляться специалистами в области геомеханики для обеспечения надежности и применимости полученных результатов в практических условиях. Это может потребовать больших вычислительных ресурсов и достаточного количества данных для обучения нейронных сетей. Однако при правильной реализации нейронные сети предоставляют мощный инструмент для анализа, прогнозирования и оптимизации геомеханических систем

Технологии нейронных сетей могут также быть использованы для описания поведения массива горных пород, подвергаемого высоким техногенным нагрузкам, и могут принести определенные преимущества в понимании и контроле за поведением горного массива. Покажем некоторые возможности применения нейронных сетей в данной области.

1. Прогнозирование деформации и разрушения.

Нейронные сети могут быть использованы для прогнозирования деформации и разрушения массива горных пород под воздействием различных техногенных нагрузок, таких как горные работы, бурение скважин и подземное строительство. На основе исторических данных о нагрузках и деформациях модель может выявить закономерности и предсказать поведение горного массива при будущих нагрузках.

2. Оптимизация процессов добычи полезных ископаемых и строительства

Нейронные сети могут быть использованы для оптимизации процессов добычи и строительства в горных породах. Модели

могут оптимизировать распределение нагрузки и параметры горных работ для минимизации риска при деформации и разрушении горной породы.

3. Анализ и прогнозирование сейсмической активности.

Нейронные сети могут быть использованы для анализа данных о сейсмической активности в окружающей среде. Модели могут выявлять закономерности сейсмических событий и прогнозировать возможные сейсмические риски в ответ на техногенные нагрузки.

4. Управление устойчивостью горного массива при добыче полезных ископаемых.

Нейронные сети могут быть интегрированы в системы управления устойчивостью массива горных пород. Модели могут анализировать данные мониторинга, предупреждать о возможных опасностях и давать рекомендации по предотвращению ущерба и минимизации риска. Нейронные сети могут использоваться для анализа больших объемов данных, поступающих от систем мониторинга горных пород, автоматически обрабатывать и анализировать данные датчиков, помогая выявлять тенденции и необычные события.

5. Модели массива горных пород могут использоваться для определения оптимальных параметров ведения подземных и открытых горных работ. Применение таких моделей позволит оптимизировать характеристики различных технологических процессов для достижения максимальной эффективности и минимизации воздействия на окружающую среду.

Таким образом, применение нейронных сетей для описания поведения массива горных пород при высоких техногенных нагрузках может значительно улучшить понимание и предсказуемость процессов в горном строительстве, добычи полезных ископаемых и других технологических процессах. Это может помочь оптимизировать процессы, улучшить безопасность и минимизировать воздействие на окружающую среду.

Обобщенная схема применения нейронных сетей показана на рис. 1.



Рис. 1. Обобщенная схема применения нейронных сетей различных архитектур для задач нелинейной геомеханики

МЕТОДЫ ОЦЕНКИ ИСПОЛЬЗОВАНИЯ НЕЙРОННЫХ СЕТЕЙ (ИНТЕРПРЕТИРУЕМОСТЬ И ОБЪЯСНИМОСТЬ)

С точки зрения рядового пользователя, нейронные сети могут показаться некоторым «черным ящиком», на вход которого подаются интересные его данные, а на выходе он получает желаемый ответ. Несмотря на то, что сегодня методы проектирования нейронных сетей в достаточной мере автоматизированы (AutoML [9], специальные фреймворки), сами полученные результаты иногда сложно объяснить, даже зная принципы построения архитектуры и работу каждого из слоев. В связи с этим сегодня активно развиваются методы, которые способствуют пониманию результатов, получаемых при использовании нейронных сетей в той или иной области. К таким методам можно отнести их оценки с помощью интерпретируемости (Interpretability) [10] и объяснимости (Explainable AI–XAI) [11].

Интерпретируемость (interpretability) нейронных сетей в нелинейной геомеханике является важным аспектом, поскольку позволяет понимать, какие конкретные факторы и зависимости оказывают наибольшее влияние на результаты моделирования или прогнозирования. В контексте нелинейной геомеханики, где взаимосвязи между различными параметрами могут быть сложными и неочевидными, интерпретируемость становится особенно важной. Рассмотрим возможности и особенности интерпретируемости для нейронных сетей в нелинейной геомеханике:

Возможности интерпретируемости:

1. Feature Importance (Важность признаков). При обучении нейронной сети можно оценить, какие признаки (параметры) входных данных оказывают наибольшее влияние на выходные результаты. Это позволяет выделить наиболее значимые параметры, которые играют ключевую роль в поведении геомеханической системы.

2. Activation Visualization (Визуализация активаций). Визуализация активаций нейронов внутри сети может помочь понять, на каких этапах и какие характеристики данных активируются. Это может помочь выявить особенности взаимодействия между различными элементами системы.

3. Partial Dependence Plots (Графики частной зависимости). Позволяют изучить, как меняется выход модели при изменении одного признака, при условии, что остальные признаки остаются постоянными. Это позволяет увидеть, как различные параметры влияют на предсказания модели.

4. Saliency Maps (Карты выделения). Позволяют определить, какие участки входных данных (например, изображений или временных рядов) оказывают наибольшее влияние на предсказание модели. В нелинейной геомеханике это может быть полезным для выявления критически важных участков объектов или территории.

Особенности интерпретируемости:

1. Компромисс между точностью и интерпретируемостью. Некоторые методы интерпретируемости могут приводить к уменьшению точности модели. Важно найти баланс между высокой точностью предсказаний и пониманием, как модель принимает решения.

2. Сложность сети и интерпретируемость. Более сложные нейронные сети могут быть менее интерпретируемыми, чем простые модели. Это связано с тем, что чем сложнее структура сети, тем труднее разбираться во внутренних механизмах её работы.

3. Объяснимость «черного ящика». Нейронные сети могут быть восприняты как «черные ящики», т.е. их решения могут быть непонятны и необъяснимы для конечных пользователей. Это может быть недопустимо в случае критически важных решений, связанных с безопасностью или стабильностью геомеханических систем.

Применения технологии интерпретируемости в нелинейной геомеханике.

1. Обоснование проектных решений. Интерпретируемость позволяет инженерам и проектировщикам понимать, почему

модель рекомендует определенные проектные решения, и доверять этим рекомендациям при создании безопасных и стабильных конструкций.

2. Распознавание критических участков. Интерпретируемость помогает выявить участки, которые могут быть наиболее подвержены деформациям или повреждениям, что позволяет предпринимать меры по их укреплению или контролю.

3. Понимание природы опасных событий. Интерпретируемость может помочь разобраться в причинах возникновения аварийных ситуаций и определить факторы, которые могут способствовать подобным событиям, что в свою очередь поможет разрабатывать эффективные меры предотвращения.

4. Анализ влияния изменения. Оценка как изменение входных параметров влияет на изменение выходных прогнозов. Может использоваться для определения наиболее чувствительных и значимых для модели параметров. Метод визуализации позволяет определить какие области входных данных (например, изображений) вносят наибольший вклад в определение класса или принятие решения моделью. Это может помочь определить, какие особенности или характеристики данных наиболее значимы для модели.

5. Feature Attribution (вклад признаков). Методы определения вклада отдельных признаков (параметров) в прогнозы или решения модели. Это позволяет определить, какие признаки наиболее важны для моделирования конкретных аспектов поведения геомеханических систем.

6. Perturbation Analysis (анализ возмущений). Метод, при котором входные данные изменяются небольшим образом и анализируются как изменения в данных отражаются на выходных прогнозах. Это может помочь определить, какие особенности входных данных модель считает наиболее важными для своих прогнозов.

7. Local Interpretable Model-agnostic Explanations (LIME). Метод, который позволяет создавать интерпретируемую локальную модель вокруг конкретного примера входных

данных. Это помогает понять, какие признаки влияют на решение модели для конкретного случая. Иными словами, анализ изменений является важным инструментом для интерпретируемости нейронных сетей в нелинейной геомеханике, поскольку позволяет углубить понимание взаимосвязей между входными и выходными данными, а также выявить критически важные параметры и факторы, которые следует учитывать при принятии решений и анализе поведения геомеханических систем.

Объяснимость Explainable AI (XAI) — это подход, который стремится сделать искусственный интеллект более прозрачным и объяснимым, позволяя понимать, какие факторы и параметры влияют на решения и прогнозы моделей. В нелинейной геомеханике, где поведение систем может быть сложным и многофакторным, XAI является особенно важным инструментом для понимания и интерпретации работы используемых нейронных сетей.

Особенности и возможности XAI для нейронных сетей в нелинейной геомеханике:

1. Интерпретируемость результатов:

- XAI позволяет понимать, какие входные данные и параметры были использованы нейронной сетью для получения конкретного выходного результата;

- это важно для понимания того, какие характеристики грунта, параметры нагрузки и другие факторы оказывают наибольшее влияние на поведение геомеханической системы.

2. Понимание неявных зависимостей:

- XAI позволяет раскрывать скрытые зависимости между входными и выходными данными, которые могут быть сложными и неочевидными: например, модель может обнаружить нелинейные взаимодействия между различными параметрами грунта и деформациями, что может помочь оптимизировать дизайн конструкции.

3. Диагностика и проверка:

- XAI помогает выявлять аномалии и ошибки в данных или моделях, что важно для обеспечения качества и достоверности результатов;

- это также может помочь в идентификации ситуаций, в которых модель может давать неточные или ненадежные прогнозы.

4. Оптимизация проектирования:

- XAI позволяет оптимизировать параметры проектирования, выявляя важные факторы и их влияние на решение модели;

- это может помочь в разработке оптимальных конструкций и фундаментов, с учетом различных условий и параметров.

5. Подтверждение безопасности и надежности:

- XAI помогает подтвердить безопасность и надежность геомеханических систем, позволяя инженерам объяснить, какие параметры и ограничения используются для обеспечения стабильности;

- это особенно важно при разработке инженерных решений, где безопасность является первостепенной задачей.

Применение Explainable AI в нелинейной геомеханике позволяет лучше понимать и интерпретировать результаты моделирования, выявлять важные зависимости и факторы, а также улучшать качество и безопасность инженерных решений. Это делает XAI мощным инструментом для обеспечения эффективности и надежности в проектировании.

Несмотря на определенную схожесть, Interpretability и Explainable AI (XAI) [12] представляют собой два подхода, которые стремятся сделать модели и алгоритмы искусственного интеллекта, в том числе нейронные сети, более понятными и объяснимыми для человека, понимать поведение геомеханических систем, закономерности и зависимости, которые обнаруживает модель. Интерпретируемость помогает исследователям и инженерам понимать причинно-следственные связи и принимать обоснованные решения на основе результатов моделирования, она уделяет внимание конкретным методам и техникам для объяснения моделей и их выводов и фокусируется на понимании, как модель делает решения, а также какие факторы влияют на результаты. Объяснимость (XAI) как технология объяснения применения ИИ представляет более широкий подход, который

стремится разработать методы и технологии для объяснения работы и выводов искусственного интеллекта, включая нейронные сети. Для задач нелинейной геомеханики ХАИ может включать в себя методы визуализации, анализа изменений, различные алгоритмы интерпретации моделей и т.д. В общем виде, интерпретируемость и объяснимость важны для применения нейронных сетей в нелинейной геомеханике, так как они помогают понять, какие факторы влияют на поведение горных систем, объясняют выводы моделей и улучшают доверие к их результатам.

ПРИМЕР РЕШЕНИЯ ЗАДАЧ НЕЛИНЕЙНОЙ ГЕОМЕХАНИКИ

В данном разделе представлен пошаговый алгоритм применения нейронной сети архитектуры U-Net [13] для решения задачи семантической сегментации изображений с трещинами:

Шаг 1: Подготовка данных.

— Соберите набор данных, содержащий изображения трещин и соответствующие карты сегментации.

— Разделите набор данных на обучающие и тестовые выборки. Для обучения и оценки модели принято делить данные в соотношении 70:30 или 80:20.

Шаг 2. Создание архитектуры U-сети.

— Определите архитектуру U-сети, состоящей из кодирующих и декодирующих устройств, соединенных мостами для хранения контекстной и пространственной информации.

— Определите количество слоев и число сверточных размерностей для каждого слоя.

— Добавьте активационные функции (например, ReLU) и механизмы регуляризации (например, dropout и batch regularisation) для повышения обобщаемости модели.

Шаг 3: Обучение модели.

— Инициализируйте веса модели, выбрав подходящий метод инициализации.

— Задайте оптимизатор (например, Adam или RMSprop) и функцию потерь (например, перекрестную энтропию), чтобы

минимизировать разницу между предсказанной картой сегментации и реальными метками.

— Обучите модель на обучающих примерах, чтобы научиться определять и сегментировать трещины на изображении.

— Используйте такие методы редактирования, как ранняя остановка и редактирование L1/L2, чтобы избежать перегрузки модели.

Шаг 4: Оценка модели.

— Протестируйте модель на тестовой выборке, чтобы оценить ее производительность и точность сегментации.

— Для оценки сходства между предсказанной картой сегментации и ожидаемыми метками используются различные метрики, такие как коэффициент Dice, индекс Жаккара, точность и индекс полноты.

Шаг 5: Итеративное уточнение.

— Проанализируйте результаты работы модели и доработайте ее на основе полученных отзывов и метрик.

— Повторите этапы обучения и оценки для улучшения результатов сегментации трещин.

Это общая схема применения архитектуры U-Net для решения задачи семантической сегментации изображений с трещинами. Конкретные шаги и параметры могут меняться в зависимости от требований и данных.

Результаты оценки трещиноватости по данным аэрофотосъемки для одного из угольных разрезов Кузбасса и карьера Хибин приводятся на рис. 2.

Анализ полей трещин, получаемых с помощью нейронной сети, этапы построения которой рассмотрены выше, приводятся на рис. 4, 5. На этих рисунках показана визуализация расчетной плотности сегментов трещин и гистограммы распределения их длин, как для Кузбасса, так и для Хибин. Их анализ показывает существенное отличие динамики формирования трещин по каждому из регионов. Как видно из рис. 3, оцениваемые плотности сегментов (измеренные в пикселях) значительно отличаются как по характеру распределения, так и по значениям (в 1,5 раза).




Рис. 2. Фотоснимки полей трещин: а (слева) — Кузбасс, б — Хибины






Рис. 4. Карты плотности сегментов трещин Кузбасс-Хибины.

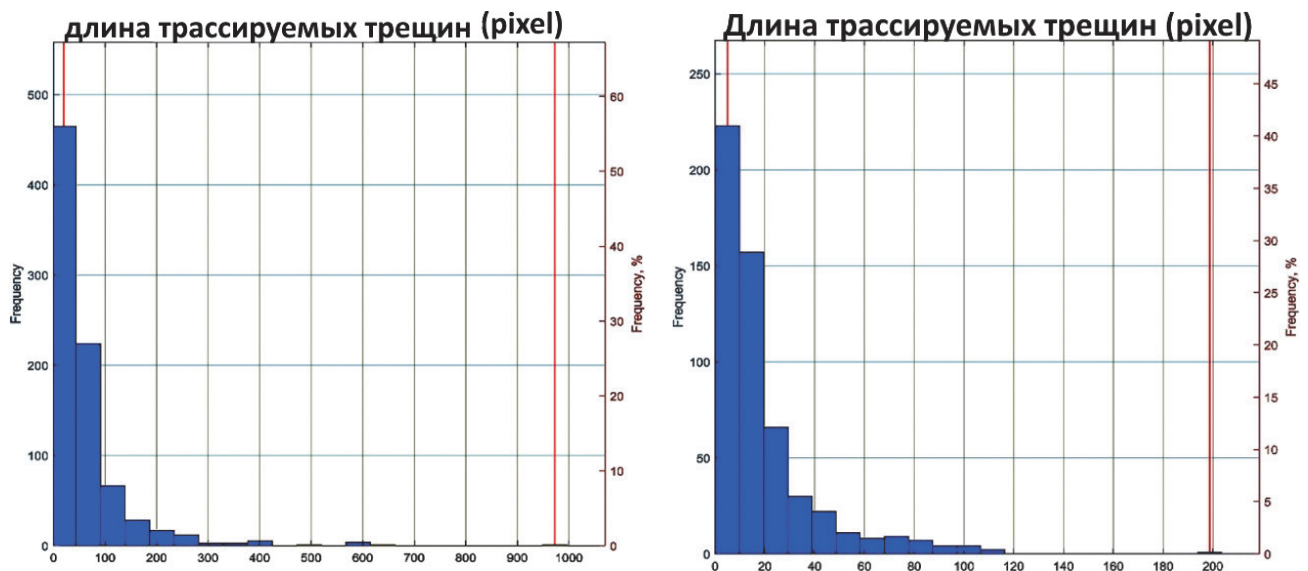


Рис. 5. Гистограмма распределения длин трещин: слева — Кузбасс, справа — Хибиньы

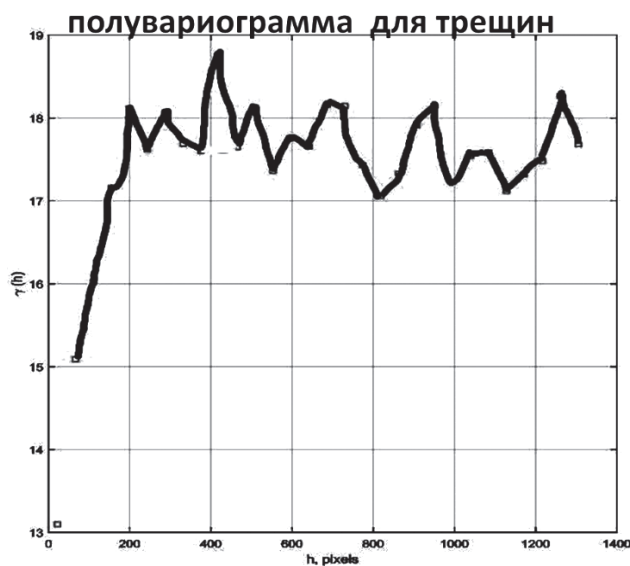


Рис. 6. Полувариограмма полей трещин для Хибиньы




Рис. 7. Полувариограмма полей трещин для Кузбасса

Для дальнейшего сравнения на рис. 5 приводятся гистограммы распределения длин трещин (в пикселях рисунка), которые показывают частоту трещин в зависимости от ее длины (для Кузбасса наиболее характерны длинные трещины с размером от 0 до 100 и частотой 450–480). В то время как для Хибиньы характерны более короткие трещины (от 0 до 40) с гораздо меньшей частотой 200–230.

Для более корректного сравнения характеристик трещин были рассчитаны так называемые, полувариограммы [14] (рис. 6, 7), которые обычно используются для анализа

пространственной автокорреляции данных. Они позволяют изучать изменение изменчивости (вариации) данных с увеличением расстояния между ними. Полувариограмма показывает насколько различаются значения двух точек данных в зависимости от расстояния между ними. На графике полувариограммы по оси X откладывается расстояние между парами точек данных, а по оси Y — среднее значение разницы между парами точек данных. Полувариограмма помогает определить есть ли автокорреляция данных (т.е. взаимосвязь между данными на различных расстояниях).

Если полувариограмма показывает увеличение значения на некотором расстоянии, то это указывает на наличие пространственной зависимости между данными. Анализ полувариограммы может предоставить информацию о том, как трещины распределены в пространстве и как далеко отдельные трещины влияют друг на друга. Как для Кузбасса, так и для Хибин полувариограммы носят характер непериодических колебаний, однако для Хибин расстояние между парами данных практически в 2 раза больше, что также говорит о том, что трещины в массиве встречаются реже. При этом диапазоны данных, между которыми имеется корреляция, также отличаются по своим значениям. По-нашему мнению, это связано с характером обрабатываемого массива горных пород (осадочные породы в Кузбассе и скальные грунты в Хибинах).

В настоящей работе показаны лишь некоторые примеры различных методов визуализации и анализа снимков с распознаением трещин нейронной сетью конкретной архитектуры (на самом деле их на сегодня существует более 20 видов, начиная от полей дилатансий и компонентов тензора напряжений, заканчивая примерами вейвлет-анализа), но учитывая ограниченный объем статьи, они не приводятся.

ЗАКЛЮЧЕНИЕ

Проведенный в работе анализ возможностей использования методов искусственного

интеллекта, в основном нейронных сетей различной архитектуры, показывает насколько широки возможности его применения для различных классов задач геомеханики ориентированных на аналитико-численные методы, информационное моделирование и обработку экспериментальных данных.

Учитывая известную универсальность таких методов, для оценки адекватности получаемых результатов их применения, нами подробно рассмотрены методы их интерпретируемости (Interpretability) и объяснимости (Explainable AI-XAI), которые необходимо использовать в практических задачах. Именно с их помощью можно определить, насколько модель на основе методов ИИ соответствует условиям решаемой задачи. В дальнейших работах мы рассмотрим конкретные задачи и применение предложенных методов оценки результатов, полученных на нейронных сетях различной архитектуры. Отметим также, что в настоящей работе подробно не рассматриваются большие лингвистические модели, которые находят сегодня все большее распространение, но мы надеемся детально рассмотреть их в развитии настоящей работы.

Благодарности. Исследование выполнено за счет гранта Российского научного фонда № 23-17-00148, <https://rscf.ru/project/23-17-00148/>

СПИСОК ЛИТЕРАТУРЫ

1. Sgurev V., Jotsov V., Kacprzyk J. (Eds.) *Advances in Intelligent Systems Research and Innovation* Springer // *Studies in Systems, Decision and Control*. 2022. No. 379. 479 p.
2. Ibrahimbegovic Adnan, Mejia-Nava Rosa-Adela. *Structural Engineering: Models and Methods for Statics, Instability and Inelasticity* Springer // *Lecture Notes in Applied and Computational Mechanics*. 2023. No. 100. 542 p.
3. Ozdemir Sinan. *Quick Start Guide to Large Language Models: Strategies and Best Practices for using ChatGPT and Other LLMs-* Addison-Wesley // Pearson Education, 2023. 132 p.
4. Kublik Sandra, Saboo Shubham *GPT-3: Building Innovative NLP Products Using Large Language Models*. O'Reilly Media, 2022. 151 p.
5. Caelen Olivier, Blete Marie-Alice. *Developing Apps with GPT-4 and ChatGPT: Build Intelligent Chatbots, Content Generators, and More* 1st edition. O'Reilly, 2023. 157 p.
6. Alto Valentina. *Modern Generative AI with ChatGPT and OpenAI Models: Leverage the capabilities of OpenAI's LLM for productivity and innovation with GPT3 and GPT4*. Packt Publishing, 2023. 285 p.

7. Hughes S. & others SQL Query Design Patterns and Best Practices: A practical guide to writing readable and maintainable SQL queries using its design patterns. Birmingham: Packt Publishing, 2023. 269 p.
8. Lee Roger. (Ed.) Computer and Information Science. Springer, 2023. 224 p.
9. Браздил П., ван Рейн Я., Соарес К., Ваншорен Х. Метаобучение. Применение в AutoML и науке о данных. Москва: ДМК Пресс, 2023. 432 с.
10. Somani A., Horsch A., Prasad D.K. Interpretability in Deep Learning. Springer, 2023. 483 p.
11. Munn Michael, Pitman David. Explainable AI for Practitioners: Designing and Implementing Explainable ML Solutions. O'Reilly Media, Inc., 2023. 279 p.
12. Mishra Pradeepta. Explainable AI Recipes: Implement Solutions to Model Explainability and Interpretability with Python. Apress Media, LLC, 2023. 272 p.
13. Zhou S.K. (ed.) Medical Image Recognition, Segmentation and Parsing. Machine Learning and Machine Learning and Multiple. Academic Press, 2016. 531 p.
14. Дэвис Дж. С. Статистический анализ в геологии. Книга 2 М.: Недра, 1990. 427 с.

DOI: 10.25558/VOSTNII.2024.58.64.004

UDC 528.88:528.8.044.2

© Т. А. Kiraeva, S. E. Popov, V. P. Potapov, 2024

T. A. KIRAEVA

Doctor of Engineering Sciences,
Leading Scientist
Mining Institute SB RAS, Novosibirsk
e-mail: coalmetan@mail.ru

S. E. POPOV

Candidate of Technical Sciences,
Senior Researcher
Federal Research Center for Information and Computational Technologies, Kemerovo
e-mail: ogidog@yandex.ru

V. P. POTAPOV

Doctor of Engineering Sciences, Professor
Leading Researcher Federal Research Center
for Information and Computational Technologies, Kemerovo
Mining Institute SB RAS, Novosibirsk
e-mail: vadimtpv@gmail.com

**NEURAL NETWORKS IN GEOMECHANICS PROBLEMS, APPLICATION POSSIBILITIES,
EVALUATION METHODS**

The paper considers some peculiarities of application of artificial intelligence (AI) methods in the tasks of geomechanics. The authors in their work highlight as the most frequently used method of artificial intelligence-neural networks [1] and analyze the possibilities of their application. Practical aspects of using neural networks for various models of geomechanics using computational, information-analytical methods,

processing of big data, description of rock mass properties, new methods of knowledge acquisition are given. For each class of models the possibilities of neural networks of different architectures are considered, which will allow us to look at the traditional ways of describing the rock massif subjected to anthropogenic impact from a new perspective. Taking into account the fact that neural networks work on the principle of “black box”, for the adequacy of their application is proposed to use the evaluation methods of their work, based on Explainable and Interpretability, which, according to the authors, will increase the efficiency of neural networks for solving applied problems of geomechanics. The authors consider some problems (detection of fracture systems and calculation of characteristics of their fields, long time series). The authors note the great potential of neural networks for the development of scientific foundations of the complex theory of field development.

Keywords: ARTIFICIAL INTELLIGENCE METHODS, NEURAL NETWORKS, EXPLAINABILITY OF MODELS, INTERPRETABILITY OF MODELS, CRACK FIELDS, INFORMATION AND ANALYTICAL MODELS, LSTM NETWORKS, CRACK ANALYSIS, NEURAL NETWORK ARCHITECTURE, BIG DATA.

REFERENCES

1. Sgurev V., Jotsov V., Kacprzyk J. (Eds.) *Advances in Intelligent Systems Research and Innovation* Springer // *Studies in Systems, Decision and Control*. 2022. No. 379. 479 p.
2. Ibrahimbegovic Adnan, Mejia-Nava Rosa-Adela. *Structural Engineering: Models and Methods for Statics, Instability and Inelasticity* Springer // *Lecture Notes in Applied and Computational Mechanics*. 2023. No. 100. 542 p.
3. Ozdemir Sinan. *Quick Start Guide to Large Language Models: Strategies and Best Practices for using ChatGPT and Other LLMs-* Addison-Wesley // Pearson Education, 2023. 132 p.
4. Kublik Sandra, Saboo Shubham *GPT-3: Building Innovative NLP Products Using Large Language Models*. O'Reilly Media, 2022. 151 p.
5. Caelen Olivier, Blete Marie-Alice. *Developing Apps with GPT-4 and ChatGPT: Build Intelligent Chatbots, Content Generators, and More* 1st edition. O'Reilly, 2023. 157 p.
6. Alto Valentina. *Modern Generative AI with ChatGPT and OpenAI Models: Leverage the capabilities of OpenAI's LLM for productivity and innovation with GPT3 and GPT4*. Packt Publishing, 2023. 285 p.
7. Hughes S. & others *SQL Query Design Patterns and Best Practices: A practical guide to writing readable and maintainable SQL queries using its design patterns*. Birmingham: Packt Publishing, 2023. 269 p.
8. Lee Roger. (Ed.) *Computer and Information Science*. Springer, 2023. 224 p.
9. Brazdil P., van Rijn J., Soares K., Vanschoren H. *Meta-learning. Applications in AutoML and Data Science*. Moscow: DMK Press, 2023. 432 p.
10. Somani A., Horsch A., Prasad D.K. *Interpretability in Deep Learning*. Springer, 2023. 483 p.
11. Munn Michael, Pitman David. *Explainable AI for Practitioners: Designing and Implementing Explainable ML Solutions*. O'Reilly Media, Inc., 2023. 279 p.
12. Mishra Pradeepta. *Explainable AI Recipes: Implement Solutions to Model Explainability and Interpretability with Python*. Apress Media, LLC, 2023. 272 p.
13. Zhou S.K. (ed.) *Medical Image Recognition, Segmentation and Parsing*. Machine Learning and Machine Learning and Multiple. Academic Press, 2016. 531 p.
14. Davis J. S. *Statistical Analysis in Geology. Book 2*. Moscow: Nedra, 1990. 427 p.