

УДК 550.8.056 (530.34)

ВОССТАНОВЛЕНИЕ ПРОСТРАНСТВЕННОГО РАСПРЕДЕЛЕНИЯ ФИЛЬТРАЦИОННЫХ СВОЙСТВ НЕОДНОРОДНЫХ ГЕОЛОГИЧЕСКИХ СРЕД ПО ВАРИАЦИЯМ МИКРОСЕЙСМИЧНОСТИ, ВОЗНИКАЮЩЕЙ В РЕЗУЛЬТАТЕ ЗАКАЧКИ ЖИДКОСТИ

© 2025 г. Е. В. Новикова^{1,*}, Н. А. Барышников^{1,**}, С. Б. Турунтаев¹, М. А. Тримонова¹

¹Институт динамики геосфер имени академика М. А. Садовского РАН, г. Москва, Россия

*E-mail: e.novikova@idg.ras.ru

**E-mail: baryshnikov.na@idg.ras.ru

Поступила в редакцию 11.10.2024 г.

После доработки 29.11.2024 г.

Принята к публикации 25.12.2024 г.

Определение свойств неоднородных коллекторов по данным об эволюции микросейсмичности является важной задачей при разработке месторождений. Анализ распространения микросейсмических событий, возникающих при закачке/отборе флюида, позволяет получить ценную информацию о проницаемости и напряженном состоянии пласта. В настоящей статье рассматривается обратная задача определения фильтрационных свойств коллектора по данным о распространении микросейсмических событий. Для этого исследуется влияние различных геологических факторов на распределение очагов микросейсмических событий. Для выявления корреляционных связей между параметрами геологической модели и эволюцией микросейсмичности были использованы методы машинного обучения. Из-за недостаточной вариативности натуральных данных для обучения модели была создана искусственная база каталогов микросейсмических событий, содержащих координаты очагов и времена их возникновения. Для этого проведено численное моделирование закачки жидкости и генерации микросейсмических событий в синтетических моделях проницаемых сред с разным геологическим строением. Таким образом, предложен комплексный подход к восстановлению фильтрационных свойств неоднородных коллекторов по данным об эволюции микросейсмичности с использованием методов машинного обучения. Предложенная методика может быть применена для оптимизации разработки месторождений, повышения эффективности извлечения флюидов и снижения рисков, связанных с возникновением нежелательной техногенной сейсмической активности.

Ключевые слова: техногенная сейсмичность, фильтрация жидкости, проницаемость, численное моделирование, машинное обучение.

DOI: 10.31857/S0002333725020091, EDN: DMCNEA

ВВЕДЕНИЕ

Закачка флюида в процессе разработки месторождений углеводородов может сопровождаться возникновением индуцированной сейсмичности [Адушкин, Турунтаев, 2015; Shapiro, 2015]. Мониторинг микросейсмических событий является одним из методов анализа процессов в геофизических объектах (месторождениях полезных ископаемых, крупномасштабных подземных объектах и т. д.). Он осуществляется с помощью сети станций, регистрирующих слабые сейсмиче-

ские сигналы. В результате анализа распространения облака микросейсмических событий могут быть получены важные сведения о процессах, протекающих в пределах исследуемого объекта, определены механические и фильтрационные свойства среды, получены данные о ее структуре и наличии неоднородностей. Ранее в ряде работ была показана возможность использования данных о распространении облака микросейсмических событий для оценки проницаемости однородной и анизотропной среды [Shapiro,

2015]. Возможность решения обратной задачи — определения локальной проницаемости неоднородной пористой среды по данным об изменении микросейсмической активности — была экспериментально продемонстрирована в ходе нашей предыдущей работы [Turuntaev и др., 2013]. Однако методики, позволяющей по данным о распространении облака микросейсмических событий в неоднородной среде оценить фильтрационные свойства на масштабах коллектора, до сих пор предложено не было.

Цель данной работы — определить возможность восстановления пространственного распределения фильтрационных свойств неоднородных геологических сред по вариациям микросейсмичности. Решение подобных обратных задач осложнено высокой степенью неопределенности и наличием нелинейных связей. Глубокие нейронные сети позволяют эффективно моделировать сложные нелинейные зависимости, что делает их эффективным инструментом для решения задач такого рода. Основная проблема создания методик на основе глубокого обучения для анализа распределенных геофизических полей состоит в отсутствии необходимого количества натуральных данных для обучения. Один из возможных путей для решения данной проблемы состоит в использовании синтетических данных для обучения модели. Для их создания мы предлагаем методику достаточно быстрого численного моделирования закачки жидкости и генерации микросейсмических событий в средах с различной геологической структурой. С помощью этой методики был создан набор из 130 тысяч синтетических микросейсмических каталогов для различных геологических условий. Полученные синтетические данные были использованы для создания модели глубокого обучения, которая позволяет по распространению облака микросейсмических событий восстанавливать пространственное распределение проницаемости модельной геологической среды. Ниже представлено подробное описание всех этапов разработки и обучения модели.

МЕТОДИКА БЫСТРОГО МОДЕЛИРОВАНИЯ РАСПРОСТРАНЕНИЯ ОБЛАКА МИКРОСЕЙСМИЧЕСКИХ СОБЫТИЙ

Численное моделирование процесса распространения облака микросейсмических событий

вследствие закачки жидкости проводилось в два этапа. На первом этапе решалась задача распространения порового давления жидкости в результате закачки в скважину, расположенную в определенной точке среды. На втором этапе по данным о распространении порового давления моделировалось распространение источников микросейсмических событий. Важно отметить, что обратные связи между этапами моделирования (например, изменение проницаемости среды под влиянием порового давления или раскрытия трещин) отсутствовали, так как это существенно усложнило бы процесс вычисления, что критично для задачи создания объемной обучающей выборки для машинного обучения.

Модельная среда представляла собой неоднородный коллектор размером $4 \times 4 \times 1$ км и глубиной залегания 1 км (рис. 1). Закачка флюида производилась в нагнетательную скважину, расположенную в центре рассматриваемого коллектора, отбор производился через добывающие скважины, расположенные по углам. Для каждого расчета величины расхода подбирались исходя из преимуществ скважин таким образом, чтобы суммарный расход добывающих скважин был примерно равен расходу нагнетательной скважины и при этом максимальные отклонения величин давления на скважинах от начального уровня находились в заданных пределах: до +0.5 МПа для нагнетательной скважины и до -0.05 МПа для добывающей.

Для получения изменяющегося во времени поля порового давления на первом этапе моделирования численно решалось уравнение однофазной неустановившейся фильтрации жидкости в проницаемой среде [Баренблатт и др., 1984]:

$$\frac{\partial P}{\partial t} = \frac{k}{m\eta} \left(\frac{1}{\beta_f} + \frac{1}{\beta_m} \right)^{-1} \Delta P + q, \quad (1)$$

где: выражение $\frac{k}{m\eta} \left(\frac{1}{\beta_f} + \frac{1}{\beta_m} \right)^{-1}$ — коэффициент пьезопроводности; k — проницаемость среды; η — вязкость жидкости; m — пористость среды; β_f и β_m — сжимаемости флюида и пористого скелета; P — давление жидкости; t — время; q — источник флюида.

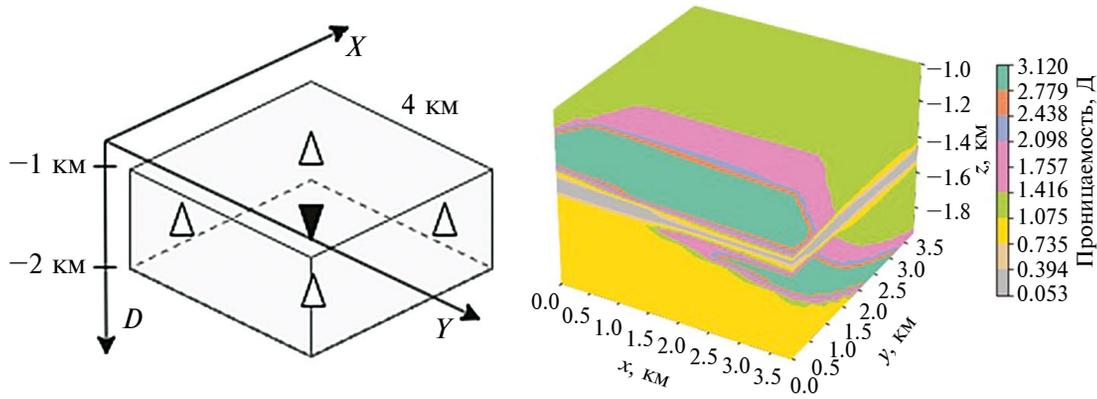


Рис. 1. Схема рассматриваемой задачи (слева). Пример пространственного распределения проницаемости модельного коллектора (справа).

Вычисление сжимаемости флюида и пористого скелета производится следующим образом:

$$\beta_f = \rho_f \frac{dP}{d\rho_f} \text{ и } \beta_m = m \frac{dP}{dm}, \quad (2)$$

где ρ_f — плотность жидкости.

Параметры модельной среды, такие как проницаемость среды, вязкость жидкости, пористость среды, плотность жидкости, представлены в табл. 1. Свободный член q в уравнении (1) представляет собой источник жидкости. Он пропорционален расходу закачиваемой жидкости, коэффициент пропорциональности определяется приемистостью скважины. В качестве начального условия задается гидростатическое

распределение давления, в качестве граничных условий — нулевой градиент давления (непроницаемые границы).

Для численного решения задачи о распространении порового давления использовалась библиотека PyPDE [Zwicker, 2020], написанная на языке Python для решения дифференциальных уравнений. На рис. 2 показан пример горизонтального разреза модели проницаемости в плоскости, содержащей скважины, и распределение порового давления в ней на некотором шаге вычисления.

На втором этапе моделирования данные о распространении порового давления использовались для решения задачи о распространении

Таблица 1. Параметры модельной среды

m	ρ_f , кг/м ³	η , сП	β_f , МПа	β_m , МПа
0.2	10 ³	2	10 ⁴	10 ⁴

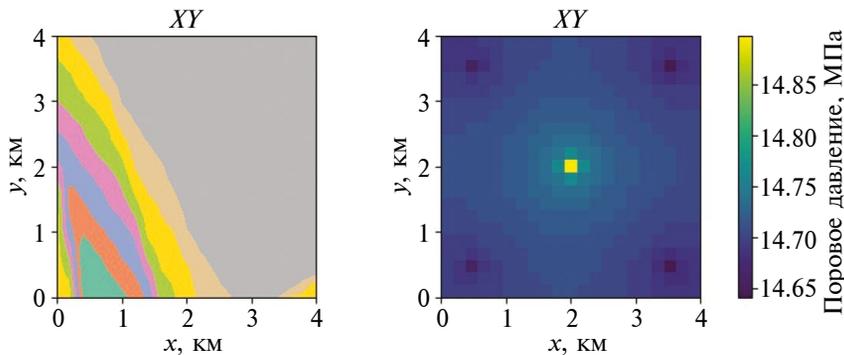


Рис. 2. Горизонтальный разрез модели проницаемости в плоскости расположения скважин (слева). Распределение порового давления на некотором шаге вычисления (справа).

облака микросейсмических событий. Для этого в каждый элементарный объем модели помещается некоторое количество $N \gg 1$ “инициаторов” событий. Каждый инициатор представляет собой некую существующую трещину, характеризующуюся направлением вектора нормали \vec{n}_i , которое задавалось через азимут α_i и угол наклона плоскости трещины γ_i (в данной работе трещины были ориентированы вертикально), и параметрами закона трения Кулона: коэффициентом трения μ_i и сцеплением C_i (табл. 2). Конкретные величины указанных параметров для каждой трещины задавались случайным образом: направления вектора нормали к трещинам распределены по нормальному закону, коэффициенты трения и сцепления — согласно распределению Вейбулла [Адушкин, Турнтаев, 2015]:

$$C_i \sim W(C_0, \lambda_C, k), \mu_i \sim W(\mu_0, \lambda_\mu, k),$$

$$\alpha_i \sim N(\alpha_0, \sigma_\alpha^2), \gamma_i \sim N(\gamma_0, \sigma_\gamma^2). \quad (3)$$

Начальное напряженное состояние породы характеризовалось тензором напряжений \vec{T}'_0 .

Для каждого элемента среды данный тензор вычислялся исходя из литостатического давления:

$$\vec{T}'_\sigma = \begin{pmatrix} \frac{v}{1-v} \int_0^H \rho_s(z) g dz & 0 & 0 \\ 0 & \frac{v}{1-v} \int_0^H \rho_s(z) g dz & 0 \\ 0 & 0 & \int_0^H \rho_s(z) g dz \end{pmatrix}, \quad (4)$$

где: ρ_s — плотность среды; H — глубина; v — коэффициент Пуассона. Далее нормальное σ_n и касательное τ напряжения для каждой трещины вычислялись по заданной ориентации вектора нормали \vec{n} к плоскости трещины (рис. 3):

$$\vec{s} = \vec{T}'_0 \cdot \vec{n} \quad (5)$$

$$\sigma_n = (\vec{T}'_0 \cdot \vec{n}) \cdot \vec{n} \quad (6)$$

$$\tau = \sqrt{\vec{s} \cdot \vec{s} - \sigma_n^2} \quad (7)$$

Событие для каждой i трещины считалось произошедшим, если для нее выполнялось усло-

Таблица 2. Параметры трещин

C_0 , МПа	λ_C , МПа	μ_0	λ_μ	k	α_0 , °	γ_0 , °
0.10	0.03	0.83	0.02	1.8	45	90

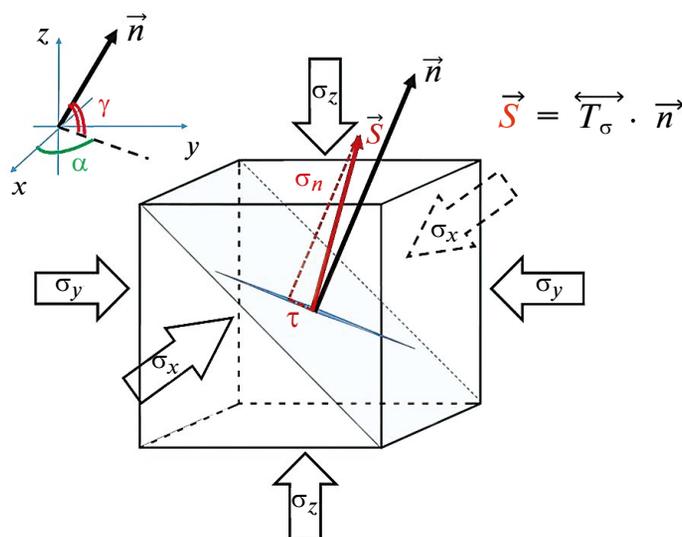


Рис. 3. Схема пересчета тензора эффективных напряжений в величины нормального σ_n и сдвигового τ напряжения на отдельной трещине. Нормаль \vec{n} к плоскости трещины задана углами α, γ , \vec{s} — вектор полного напряжения.

вие Кулона–Мора [Адушкин, Турунтаев, 2015; Shapiro, 2015; Zoback, 2012]:

$$\tau_i \geq C_i + \mu_i(\sigma_{ni} - P). \quad (8)$$

Таким образом, в каждом элементарном объеме среды имелось N потенциальных источников микросейсмических событий со случайно распределенными параметрами. В процессе распространения порового давления для определенной части из них выполнялся критерий (8). При этом за число событий на каждом шаге вычислений считалось приращение количества инициированных трещин (каждая трещина могла стать источником события только один раз). После нормировки на число трещин результат моделирования представлял собой плотность сейсмических событий (рис. 4), которая на следующем этапе использовалась для составления модельных каталогов событий.

СОЗДАНИЕ БАЗЫ ДАННЫХ СИНТЕТИЧЕСКИХ МИКРОСЕЙСМИЧЕСКИХ КАТАЛОГОВ СОБЫТИЙ

В природе фильтрационные свойства горных пород разнообразны и непостоянны, они могут меняться с течением времени в связи с естественными природными процессами (землетрясения, эрозия почв из-за подземных течений, выход метанов из подземных газовых хранилищ на поверхность). Записей и информации о различном структурном строении пород существует не так много, и они не отличаются сильной ва-

риативностью из-за ограниченного количества мест проведения сейсмического мониторинга. Для достижения цели настоящего исследования необходимо иметь большую базу данных о среде: ее строении, составе, изменении порового давления вследствие закачки жидкости. Так как натуральных данных недостаточно, была использована база данных синтетических геологических моделей с различным строением и свойствами пород (рис. 5), которые были получены авторами работы [Jessell и др., 2022] в результате численного моделирования случайного набора комбинаций геологических процессов: поэтапное деформирование начальной слоистой структуры, сдвиги, неоднородные включения, выветривание и формирование осадочных пород.

Данные модели представляют из себя трехмерные матрицы со сторонами 4 км и шагом сетки 20 м, содержащие метки класса и величины плотностей породы, соответствующие 35 различным горным породам. Каждой породе нами было присвоено случайное значение проницаемости в соответствии с таблицей (табл. 3) параметров логнормального распределения для четырех типов пород [Scibek, 2020].

Таким образом был создан набор данных, содержащий 130 тысяч случайных геологических моделей. Для каждой такой модели по описанной ранее методике было проведено моделирование изменения во времени поля порового давления и плотности микросейсмических событий в результате закачки жидкости. Далее полученная плотность микросейсмических событий нормировалась таким образом, чтобы ее

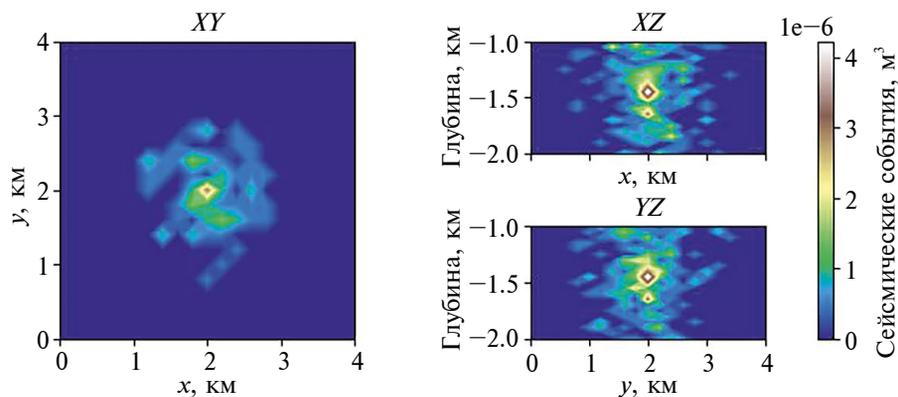


Рис. 4. Пространственное распределение событий, произошедших от момента начала закачки. Показаны события во взаимно перпендикулярных плоскостях, проходящих через точку закачки жидкости. На цветовой шкале отражена плотность сейсмических событий — отношение количества событий в элементарном объеме модели к количеству инициаторов событий N .

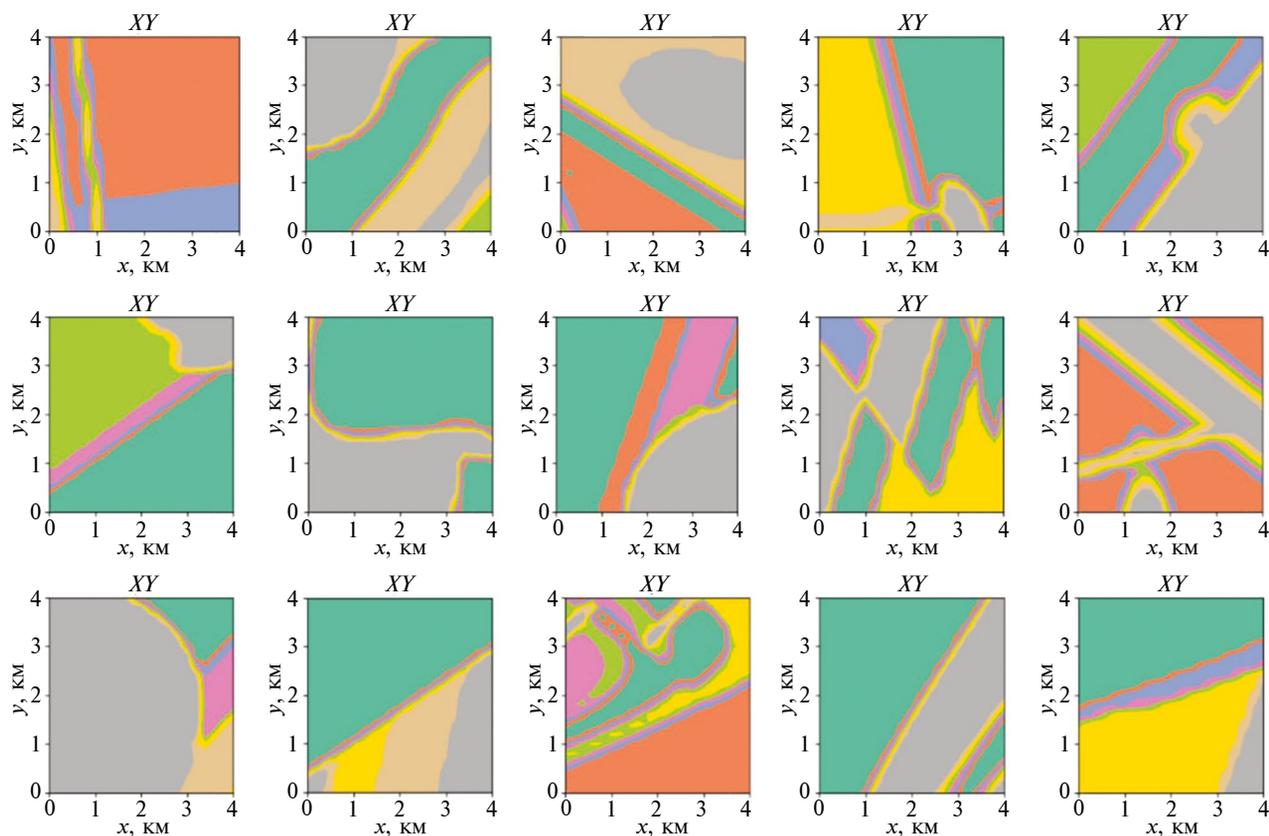


Рис. 5. Пример синтезированных моделей неоднородного коллектора: разрез модели проницаемости в плоскости XY, содержащей точку расположения источника.

Таблица 3. Параметры логнормального распределения, использованного при выборе случайного значения проницаемости для четырех типов пород

Тип горной породы	Средняя проницаемость ($\log_{10}(\text{Мд})$)	СКО ($\log_{10}(\text{Мд})$)
Интрузивные	1.56	0.58
Метаморфические	2.00	0.57
Вулканические	2.77	0.46
Осадочные	3.08	0.23

интеграл по пространству и времени был равен заданному числу событий — 1000. После чего генерировался случайный каталог событий: в каждом элементе среды на каждом шаге по времени событие инициировалось с вероятностью, пропорциональной плотности событий. Это было необходимо, чтобы избежать корреляции между количеством событий и остальными парамет-

рами геологической модели: так как проницаемость пород варьировалась в диапазоне трех порядков, то моделирование без нормировки плотности событий привело бы к существенному различию суммарного количества событий. Нашей же целью было создать модель машинного обучения, восстанавливающую параметры среды на основе распределения событий, но не их суммарного количества. Дополнительно в каталоги было добавлено значение магнитуды событий, которое назначалось случайным образом, исходя из экспоненциального распределения так, чтобы выполнялся линейный закон повторяемости землетрясений. Величина магнитуды в предложенной модели не несет дополнительной информации о среде, но может быть использована в дальнейшем в случае зависимости параметров закона повторяемости от распределенных геофизических величин (поровое давление, напряженно-деформированное состояние, характеристики среды [Ritz et al., 2022]). В результате для каждой модели среды

был получен каталог из примерно 1000 событий, содержащий время, координаты и магнитуду события (рис. 6).

МОДЕЛЬ ГЛУБОКОГО МАШИННОГО ОБУЧЕНИЯ ДЛЯ ВОССТАНОВЛЕНИЯ ПРОНИЦАЕМОСТИ СРЕДЫ

Модель глубокого обучения — это сложный математический алгоритм, который принимает на вход исходный набор (вектор или тензор) данных и последовательно применяет к нему линейные преобразования и функции активации. Линейные преобразования изменяют входной вектор, задавая его новое представление в пространстве признаков. Функции активации — “нейроны” — это дифференцируемые нелинейные функции, которые позволяют модели учитывать сложные зависимости в данных и выявлять нелинейные закономерности, недоступные при использовании только линейных операций. Коэффициенты линейных преобразований настраиваются в процессе обучения, которое сводится к оптимизации функционала качества (функции потерь), например, минимизации среднеквадратичного отклонения между предсказаниями модели и целевыми значениями.

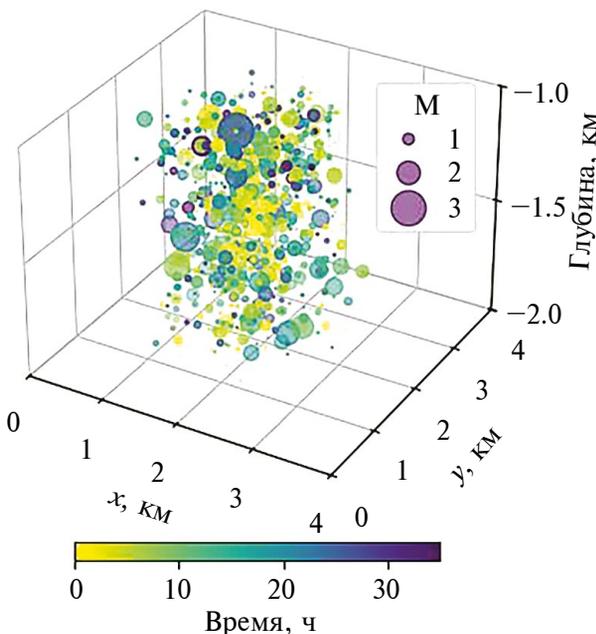


Рис. 6. Пример распределения микросейсмических событий разной магнитуды в разные моменты времени.

Для этого используется метод градиентного спуска (или его разновидности), который вычисляет направление и шаг изменения параметров на основе градиента функционала. Обучение модели происходит итеративно: на каждом шаге вычисляются ошибки, обновляются параметры, и процесс повторяется. Одна полная обработка всего набора данных называется эпохой, а обучение модели обычно включает множество эпох, чтобы обеспечить достижение оптимального результата.

Схема предлагаемой нами модели глубокого обучения для восстановления фильтрационных свойств неоднородного коллектора по данным о распространении облака микросейсмических событий показана на рис. 7.

Модель была реализована с использованием библиотеки глубокого обучения Pytorch, программный код модели доступен по адресу [https://github.com/idlgfd/permeability_reconstruction_network/blob/main/the_whole_workflow.ipynb]. На вход модели подается каталог из $N = 1000$ событий, каждое событие представлено вектором из 5 значений (t, x, y, d, M) . Далее каждое событие кодируется вектором чисел из 27 значений. Для этого используется полносвязный слой, состоящий из последовательности 5 линейных слоев и функций активации (ReLU). Поле этого массива закодированных векторов событий поступает в модуль трансформер-энкодера [Vaswani et al., 2017]. Данный модуль, построенный на основе скалярных произведений входящих векторов данных, преобразует каждый вектор с учетом контекста всех прочих векторов. В работе была использована стандартная реализация трансформер-энкодера из библиотеки Pytorch. Далее вектора событий преобразуются в трехмерные матрицы $(3, 3, 3)$, после чего массив получившихся матриц поступает на вход сверточной нейронной сети, состоящей из 5 сверточных (Transposed convolution 3D) слоев с ядром $(3, 3, 3)$, последовательно повышающих размерность массива матриц событий до конечного размера модели среды $(21, 21, 21)$. При этом каждое событие выступает в роли отдельного канала исходного “изображения”. В результате на выходе модели получается матрица с размерностью $(21, 21, 21)$, представляющая собой трехмерное пространственное распределение проницаемости пласта.

T , час	X , км	Y , км	D , км	M
1	2	2.1	-1.5	0.1
2	2.1	1.9	-1.2	0.3
...
N	3.8	2.9	-1.9	0.0

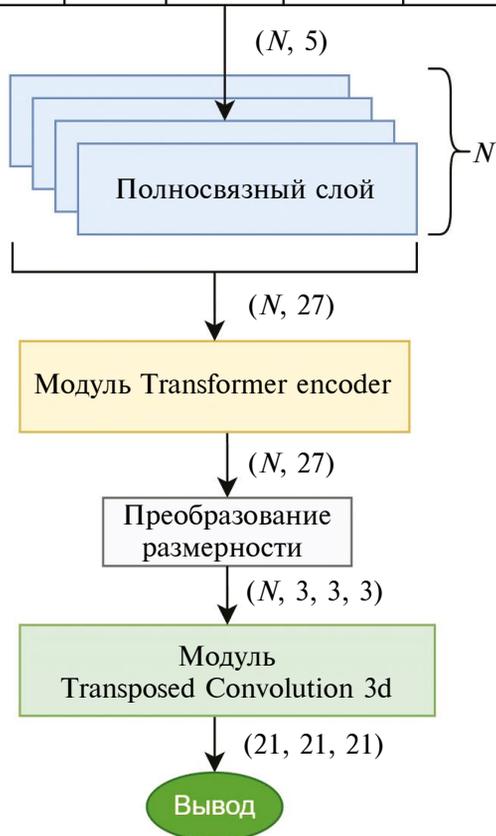


Рис. 7. Схема реализованной модели. В скобках указаны размерности тензоров данных, получаемых на каждом этапе работы модели, $N = 1000$ — количество событий в одном каталоге.

ОБУЧЕНИЕ МОДЕЛИ

В процессе обучения в качестве функции потерь было использовано среднеквадратическое отклонение десятичных логарифмов проницаемости модели пласта (выраженной в миллиардах). При этом матрица из попарных отклонений в каждой точке модели пласта дополнительно умножалась на маску из коэффициентов штрафа.

$$l = \frac{1}{21^3} \sum_{x,y,d} f_{x,y,d} \cdot \left(\log(k_{x,y,d}) - \log(\hat{k}_{x,y,d}) \right)^2,$$

где: k — матрица истинной проницаемости; \hat{k} — матрица предсказанной проницаемости; f — матрица коэффициентов штрафа (мультипликатор). Дело в том, что события в исходных данных в основном сгруппированы вокруг нагнетающей скважины и практически отсутствуют ближе к границам модельного пласта. Из-за этого большинство точек пласта относится к областям, где не произошло ни одного события, и в которых, следовательно, нет никакой информации для оценки проницаемости среды. Модели неоткуда брать информацию об этих точках, поэтому без введения дополнительных коэффициентов штрафа обучение становится неэффективным. Маска коэффициентов штрафа представляет собой пространственное нормированное распределение средней плотности событий по всей обучающей выборке (рис. 8). В центре, где количество событий максимально, коэффициент штрафа равен 1, на периферии — 10^{-3} . Введение маски штрафов позволило придать большее значение ошибкам в тех областях модельного пласта, где больше информации для более точной оценки проницаемости, и меньшее значение в областях, в которых нужная информация скорее всего отсутствует. Тем самым нам удалось повысить точность предсказания модели там, где оно в принципе возможно.

Для обучения модели был использован оптимизатор Adam. Обучение проводилось с использованием технологии CUDA на видеокарте пользовательского уровня (NVIDIA GeForce 1660 GTX Super). Время обучения 1 эпохи составляло порядка 20 минут. Для удовлетворительного обучения модели на использованной обучающей выборке было достаточно 30 эпох, приращение точности на последующих эпохах было незначительным. В процессе обучения была проведена оптимизация параметров самой модели (размерности и количество линейных слоев, количество слоев трансформер-энкодера, размерность ядра сверточных слоев), а также параметров обучения (скорость обучения), обеспечивающих минимальное значение функции потерь при обучении в течение 5 эпох.

РЕЗУЛЬТАТЫ

На рис. 9 показан пример исходного и восстановленного трехмерного пространственного распределения проницаемости для одного

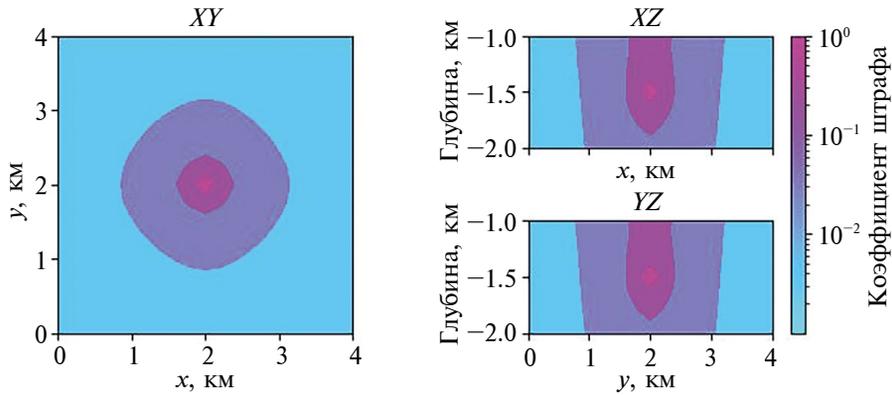


Рис. 8. Маска штрафов — пространственное распределение мультипликатора функции потерь. Показаны горизонтальный и два вертикальных среза, проходящих через точку нагнетания жидкости в центре пласта.

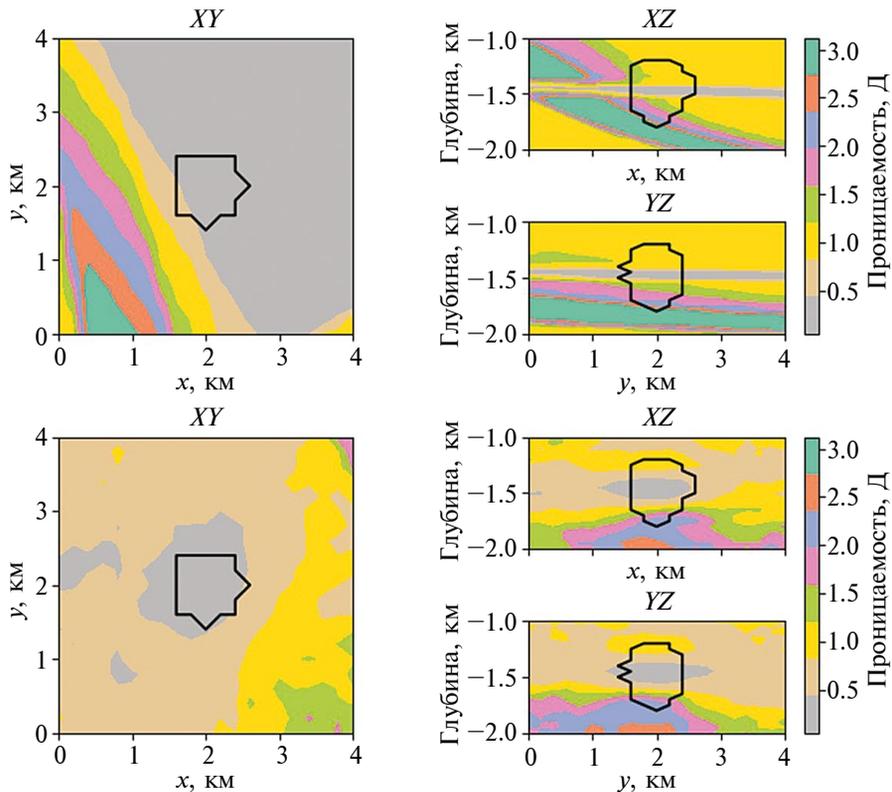


Рис. 9. Пример исходного (сверху) и восстановленного (снизу) трехмерного пространственного распределения проницаемости модельного пласта. Показаны горизонтальный и два вертикальных среза, проходящих через точку нагнетания жидкости в центре пласта. Контуром отмечена область с наибольшей точностью восстановления ($\sigma \leq \log_{10}(2) \approx 0.3$).

из модельных каталогов событий тестовой выборки. Контуром обведена область вблизи точки нагнетания жидкости с наибольшей точностью восстановления (далее о ней будет рассказано подробнее).

В ходе применения модели на данных тестовой выборки было установлено, что модель

способна достаточно точно выделять области с большим контрастом проницаемости. При этом мелкомасштабные детали, такие как прослойки породы или включения, выделяются гораздо хуже. На рис. 10 показаны результаты применения модели для восстановления проницаемости однородного коллектора с различной

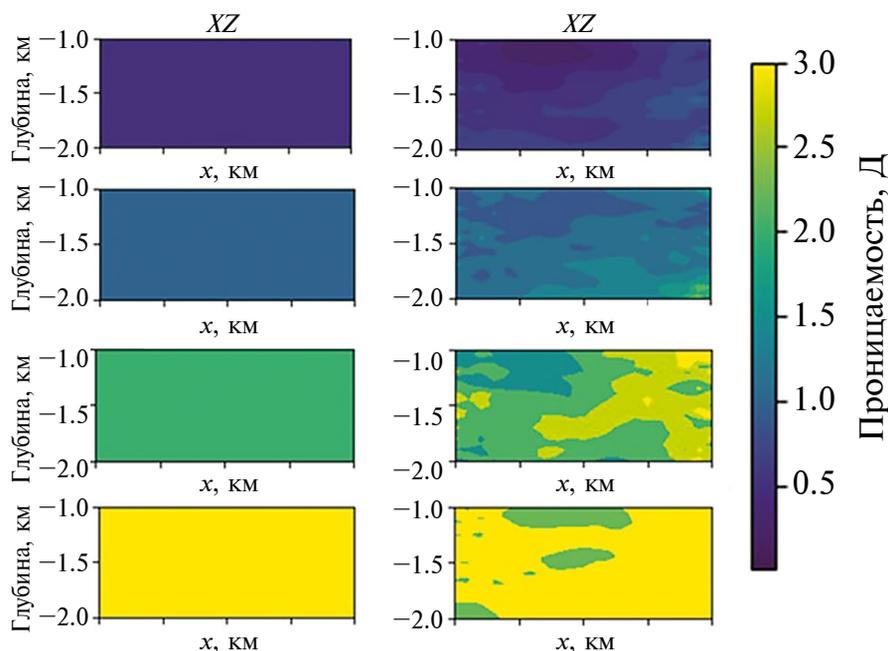


Рис. 10. Результат восстановления фильтрационных свойств для набора однородных моделей коллектора. Слева представлены исходные значения проницаемости, справа — восстановленные (разрез в плоскости XZ).

проницаемостью (слева показаны исходные данные, справа — восстановленные). На рис. 11 показаны результаты восстановления проницаемости однородного коллектора, содержащего слой более проницаемой породы. На рис. 12 показаны графики соответствия, построенные по тем же данным: слева — для однородного коллектора, справа — для коллектора, содержащего слой более проницаемой породы (на графике отражена проницаемость слоя). Оценка точности восстановленных значений проницаемостей в однородных коллекторах производилась в области около нагнетательной скважины (в кубе со стороной 240 м), в коллекторах с более проницаемым слоем — в аналогичной области внутри более проницаемого слоя.

В ходе анализа ошибок также было проведено восстановление пространственного распределения проницаемостей для всей тестовой выборки. Было установлено, что ошибка определения проницаемости в каждой отдельной ячейке модельного пласта распределена по закону, близкому к логнормальному, что эквивалентно нормальному закону распределения ошибки определения порядка величины проницаемости $\log_{10}(k - \hat{k}) \sim N(\sigma^2, 0)$. Это является следствием вида функции потерь: в процессе обучения минимизировалось среднеквадратичное отклоне-

ние десятичных логарифмов проницаемости. Таким образом, средняя относительная ошибка определения (с учетом асимметрии) не зависит от самой величины проницаемости (см. Приложение 1). На рис. 13 показано пространственное распределение параметра σ — стандартного отклонения ошибки определения порядка величины проницаемости, усредненного по всей тестовой выборке. Наибольшая точность модели достигается в точке закачки жидкости. Средняя ошибка определения порядка проницаемости (измеренной в миллиардах) в этой области составила около 0.18, что эквивалентно средней относительной ошибке определения самой проницаемости около 50% (в большую сторону, учитывая асимметрию распределения). Контуром на рис. 9 и рис. 10 отмечена область с параметром $\sigma \leq \log_{10}(2) \approx 0.3$, что эквивалентно средней относительной ошибке в 100%.

На рис. 14 показан график зависимости того же параметра σ от среднего по тестовой выборке количества событий в каждой ячейке модельного пласта. Пунктирной линией показана линейная регрессия. Можно видеть, что средняя ошибка убывает с увеличением числа событий, однако для достижения относительной ошибки порядка 25% ($\log_{10}(\sigma) - 1 \approx 0.25$) необходимо на порядок большее количество событий.

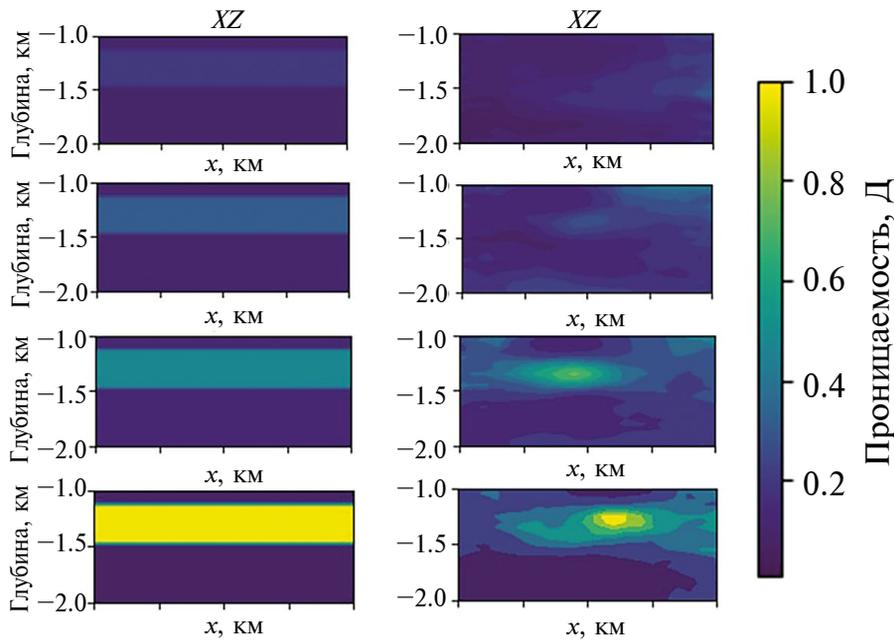


Рис. 11. Результат восстановления фильтрационных свойств для набора однородных моделей коллектора с более проницаемым слоем пород. Слева представлены исходные значения проницаемости, справа — восстановленные проницаемости (разрез в плоскости XZ).

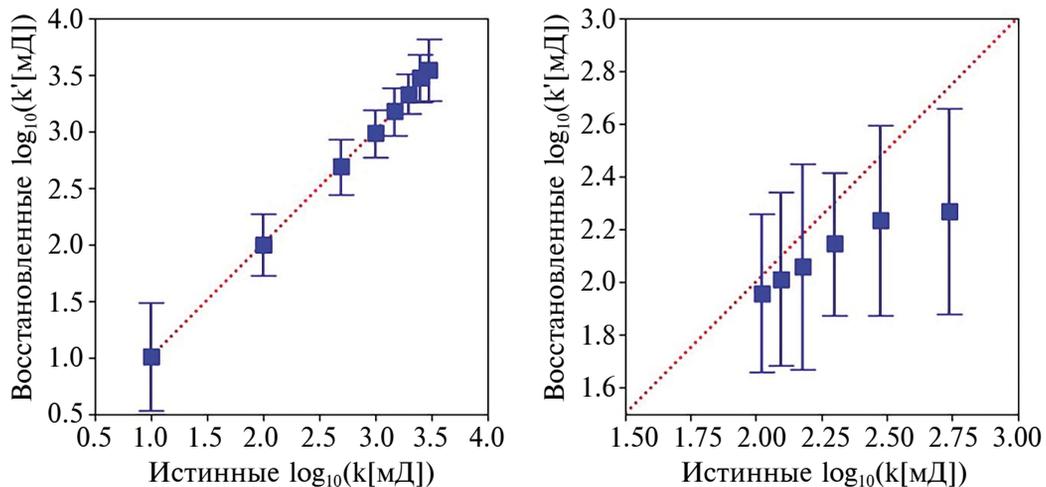


Рис. 12. Сравнение истинных и восстановленных значений логарифма проницаемости для однородных коллекторов (слева) и для однородных коллекторов с более проницаемым слоем (справа).

ОБСУЖДЕНИЕ

Основная проблема создания методик на основе глубокого обучения для анализа распределенных геофизических полей состоит в недостатке реальных данных для обучения моделей. В рамках данного исследования мы сгенерировали обширный синтетический набор данных, включающий 130 тысяч моделей геоло-

гической среды с суммарной площадью порядка полумиллиона квадратных километров, что сопоставимо с площадью Франции. Обучение моделей на меньших объемах данных (10 тысяч моделей) к удовлетворительным результатам не привело. При этом получение реальных данных даже такого масштаба и однородности в настоящее время практически невозможно.

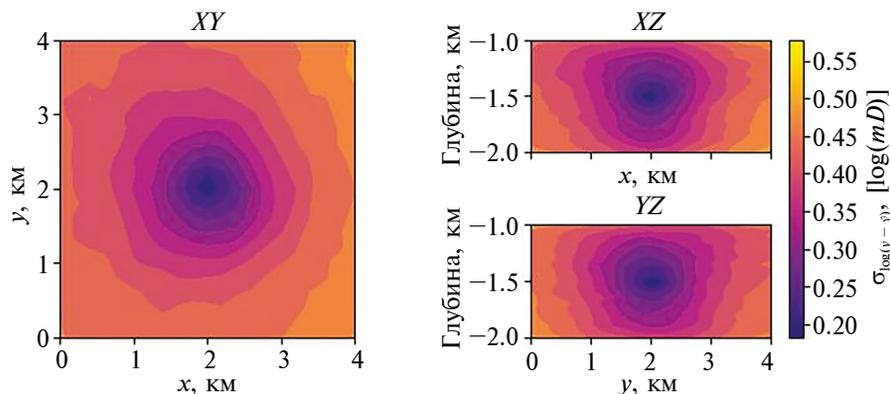


Рис. 13. Пространственное распределение параметра σ (стандартного отклонения ошибки определения порядка величины проницаемости), усредненного по всей тестовой выборке. Показаны горизонтальный и два вертикальных среза, проходящих через точку нагнетания жидкости в центре пласта.

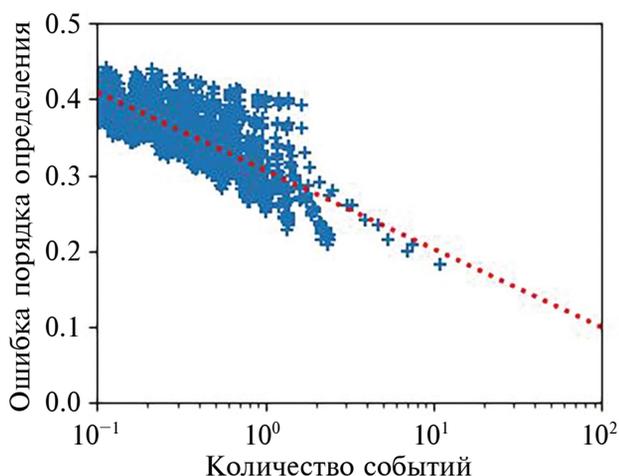


Рис. 14. Зависимость параметра σ от среднего по тестовой выборке количества событий в каждой ячейке модельного пласта. Пунктирной линией показана линейная регрессия.

Использование синтетических данных позволяет решить проблему недостатка данных, однако создает другую проблему, связанную с их неполным соответствием реальным данным.

В данной работе моделировался процесс распространения облака микросейсмических событий. Минимальный набор параметров среды, необходимый для проведения подобного численного моделирования, включает в себя параметры закона трения (коэффициент трения, сцепление), механические параметры (плотность, коэффициент Пуассона, объемный модуль сжатия), фильтрационные (пористость, проницаемость), свойства флюида (вязкость, сжимаемость, плотность), структурные (ориен-

тация трещиноватости). То есть даже в предельно упрощенном варианте расчет требует большого объема данных, существенно влияющих на результат и сильно рознящихся в зависимости от рассматриваемого коллектора. Создание обучающей выборки, охватывающей все возможные комбинации пространственного распределения данных параметров, представляется невозможным. Помимо этого, на возникновение и кластеризацию микросейсмических событий существенно влияют локальная неоднородность поля напряжений и наличие крупномасштабных разломов [Dichiarante et al., 2021]. В данной работе было использовано упрощенное представление о литостатическом распределении давления, не допускающее возникновения кластеров событий: все события локализируются вблизи нагнетательной скважины. Чтобы исправить этот недостаток, необходимо либо иметь достаточно точные сведения о неоднородном строении коллектора, либо в соответствии с некоторой моделью варьировать пространственное распределение напряжений при создании данных для обучения. Оба этих варианта на данный момент представляются мало осуществимыми. Сказанное выше приводит нас к выводу, что получение полезной с практической точки зрения методики восстановления фильтрационных свойств среды по данным о распространении облака микросейсмических событий возможно только в рамках более локальных сценариев. Данные для обучения модели должны специально создаваться под конкретные имеющиеся сведения о строении и свойствах рассматриваемого пласта, историю закачки жидкости и результаты сейсмического

мониторинга. Это позволит существенно сузить набор и диапазон варьируемых свойств при создании синтетических данных и в результате получить более специализированную, но зато и более точную модель для восстановления фильтрационных свойств. Представленную в данной работе методику можно рассматривать как дополнительный способ анализа данных микросейсмического мониторинга с целью получения сведений о свойствах массива, не требующий существенных финансовых затрат и дополнительного оборудования.

ВЫВОДЫ

В результате проведенного исследования предложена методика для восстановления пространственного распределения фильтрационных свойств неоднородного коллектора по данным о распространении облака микросейсмических событий, вызванного закачкой/отбором жидкости. Методика включает в себя создание базы данных синтетических каталогов событий для набора модельных неоднородных сред с использованием численного моделирования динамики поля порового давления в условиях рассматриваемой задачи, которая затем используется для создания модели на основе метода глубокого машинного обучения. Разработанная методика применена к задаче об эволюции микросейсмичности, вызванной закачкой жидкости с постоянным расходом в модельный неоднородный коллектор. Полученная в результате модель позволяет восстанавливать крупномасштабные неоднородности среды внутри области с радиусом порядка 250 м вокруг нагнетательной скважины. Ограничения модели связаны прежде всего с необходимостью учета большого числа параметров геофизических полей, которые могут быть неизвестны, а также с недостаточным количеством реально регистрируемых событий. Возможное практическое использование разработанной методики предполагает целевое создание модели под конкретные параметры района наблюдения и данные сейсмического мониторинга. В таком виде ее можно рассматривать как дополнительный способ анализа данных микросейсмического мониторинга с целью получения сведений о свойствах массива, не требующий существенных финансовых затрат и дополнительного оборудования.

ПРИЛОЖЕНИЕ. ОЦЕНКА ОТНОСИТЕЛЬНОЙ ОШИБКИ ПРИ ЛОГНОРМАЛЬНОМ РАСПРЕДЕЛЕНИИ ВЕЛИЧИНЫ

Пусть σ — параметр стандартного отклонения в логнормальном распределении ошибки определения проницаемости k , то есть $\log_{10}(k - \hat{k}) \sim N(\sigma^2, 0)$. Тогда величина логарифма проницаемости, определенного моделью $\hat{y} = \log_{10}(\hat{k})$, с учетом доверительного интервала, будет лежать в промежутке $y - 3 * \sigma < \hat{y} < y + 3 * \sigma$, а средняя величина ее ошибки составит σ . Тогда величина проницаемости будет лежать в промежутке $k * 10^{-3\sigma} < \hat{k} < k * 10^{3\sigma}$, а относительная ошибка попадет в интервал $1 - 10^{-3\sigma} < \frac{k - \hat{k}}{k} < 10^{3\sigma} - 1$, то есть не будет зависеть от величины самой проницаемости. Среднюю ошибку определения проницаемости при этом можно оценить как $1 - 10^{-\sigma}$ и $10^{\sigma} - 1$ в меньшую и большую сторону соответственно.

СПИСОК ЛИТЕРАТУРЫ

- Адушкин В. В., Турунтаев С. Б. Техногенная сейсмичность — индуцированная и триггерная. М.: ИДГ РАН. 2015а. 364 с.
- Баренблатт Г. И., Ентов В. М., Рыжик В. М. Движение жидкостей и газов в природных пластах. М.: Недра. 1984. 211 с.
- Dichiarante A.M., Langet N., Bauer R.A., Goertz-Allmann B.P., Williams-Stroud S.C., Kühn D., Oye V., Greenberg S.E., Dando B.D.E. Identifying geological structures through microseismic cluster and burst analyses complementing active seismic interpretation // Tectonophysics. 2021. Т. 820. С. 229107.
- Jessell M., Guo J., Li Y., Lindsay M., Scalzo R., Giraud J., Pirot G., Cripps E., Ogarko V. Into the Noddyverse: a massive data store of 3D geological models for machine learning and inversion applications // Earth Syst Sci Data. 2022. Т. 14. № 1. С. 381–392.
- Ritz V., Rinaldi A. P., Wiemer S. Transient evolution of the relative size distribution of earthquakes as a risk indicator for induced seismicity // Commun Earth Environ. 2022. Т. 3.
- Scibek J. Multidisciplinary database of permeability of fault zones and surrounding protolith rocks at world-wide sites // Sci Data. 2020. Т. 7. № 1. С. 95.
- Shapiro S. Fluid-Induced Seismicity. Cambridge: Cambridge University Press. 2015.
- Turuntaev S., Ereemeeva E., Zenchenko E. Laboratory study of microseismicity spreading due to pore pressure change // J. Seismol. 2013. Т. 17.

Vaswani A., Shazeer N.M., Parmar N., Uszkoreit J., Jones L., Gomez A.N., Kaiser L., Polosukhin I. Attention is all you need. *Adv Neural Inf Process Syst.* 2017. Т. 2017-Decem. № Nips. С. 5999–6009.

Zoback M. D. Managing the seismic risk posed by wastewater disposal // *Earth Magazine.* 2012. С. 38–43.

Zwicker D. A Python package for solving partial differential equations // *J. Open Source Softw.* 2020. Т. 5. № 48. С. 2158. [idglgfd/permeability_reconstruction_network](https://github.com/idglgfd/permeability_reconstruction_network) [Электронный ресурс].

URL: https://github.com/idglgfd/permeability_reconstruction_network (дата обращения: 15.08.2024).

Reconstruction of the Spatial Distribution of Filtration Properties of Heterogeneous Geologic Media Based on Variations of Microseismicity Resulting from Fluid Injection

E. V. Novikova^{a, *}, N. A. Barishnikov^{a, **}, S. B. Turuntaev^a, and M. A. Trimonova^a

^a*Sadovsky Institute of Geospheres Dynamics of Russian Academy of Sciences, Moscow, Russia*

^{*}*e-mail: e.novikova@idg.ras.ru*

^{**}*e-mail: baryshnikov.na@idg.ras.ru*

Received October 10, 2024; revised November 29, 2024; accepted December 25, 2024

Abstract — Determining the properties of heterogeneous reservoirs based on microseismic evolution data is an important task in field development. Analyzing the propagation of microseismic events occurring during fluid injection/withdrawal provides valuable information about permeability and stress state of the reservoir. In this paper, we consider the inverse problem of determining reservoir filtration properties from microseismic event propagation data. For this purpose, the influence of various geological factors on the distribution of microseismic event sources is investigated. Machine learning methods were used to identify correlations between geologic model parameters and microseismicity evolution. Due to the insufficient variability of in-situ data, an artificial database of catalogs of microseismic events containing the coordinates of sources and their occurrence times was created to train the model. For this purpose, numerical modeling of fluid injection and generation of microseismic events in synthetic models of permeable media with different geological structure was carried out. Thus, a comprehensive approach to the restoration of filtration properties of heterogeneous reservoirs from microseismicity evolution data using machine learning methods is proposed. The proposed methodology can be applied to optimize field development, improve the efficiency of fluid extraction and reduce the risks associated with the occurrence of undesirable anthropogenic seismic activity.

Keywords: anthropogenic seismicity, fluid filtration, permeability, numerical modeling, machine learning