DOI: 10.51790/2712-9942-2022-3-1-1

РЕШЕНИЕ ОБРАТНЫХ ЗАДАЧ СЕЙСМОРАЗВЕДКИ ТРЕЩИНОВАТЫХ ПЛАСТОВ МЕТОДАМИ МАШИННОГО ОБУЧЕНИЯ

М. В. Муратов[а], Д. И. Петров[б], В. В. Рязанов[в], В. А. Бирюков[г]
Московский физико-технический институт, г. Долгопрудный, Российская Федерация
[а] *ORCID: http://orcid.org/0000-0003-4958-8856, max.muratov@gmail.com*
[б] *ORCID: http://orcid.org/0000-0001-6110-4485, diapetr@gmail.com*
[в] *ORCID: https://orcid.org/0000-0003-4706-598X, vasyarv@mail.ru*
[г] *ORCID: http://orcid.org/0000-0003-0109-8567, biryukov.vova@gmail.com*

Аннотация: в данной работе решаются обратные задачи сейсморазведки в средах с однородно ориентированными трещиноватыми включениями с применением сверточных нейронных сетей. Выбор данного вида нейронных сетей определен большой размерностью массива данных. Построение обучающей выборки из прямых задач для обучения нейронной сети осуществляется с помощью математического моделирования. Для численного решения прямых задач был взят сеточно-характеристический метод на неструктурированных сетках. Выбор численного метода обусловлен волновой природой изучаемых динамических процессов, которая хорошо учитывается сеточно-характеристическим методом. Данный подход хорошо зарекомендовал себя при построении корректных вычислительных алгоритмов для граничных и контактных условий, в частности, для задания дискретного массива трещин. Целью работы является определение характеристик одиночной трещины и пластов таких трещин. Была успешно решена обратная задача сейсморазведки для пласта трещин с шестью неизвестными параметрами: высота и угол наклона трещин, плотность расположения трещин, горизонтальная протяженность пласта и его пространственное положение в 2D. В процессе обучения нейронной сети и распознавания элементов валидационной выборки, помимо данных о скоростях колебаний в массиве сейсмических данных, на вход сети также подавался их частотный спектр.

Ключевые слова: машинное обучение, сверточные нейронные сети, математическое моделирование, сеточно-характеристический метод, сейсморазведка, обратные задачи, трещиноватые среды.

Благодарности: работа выполнена при поддержке РФФИ, грант № 20-01-00572.

Для цитирования: Муратов М. В., Петров Д. И., Рязанов В. В., Бирюков В. А. Решение обратных задач сейсморазведки трещиноватых пластов методами машинного обучения. *Успехи кибернетики*. 2022;3(1):8–13. DOI: 10.51790/2712-9942-2022-3-1-1.

MACHINE LEARNING APPLICATIONS TO SOLVING INVERSE PROBLEMS IN FRACTURED LAYER SEISMIC SURVEYS

M. V. Muratov[a], D. I. Petrov[b], V. V. Ryazanov[c], V. A. Biryukov[d]
Moscow Institute of Physics and Technology, Dolgoprudnyi, Russian Federation
[a] *ORCID: http://orcid.org/0000-0003-4958-8856, max.muratov@gmail.com*
[b] *ORCID: http://orcid.org/0000-0001-6110-4485, diapetr@gmail.com*
[c] *ORCID: https://orcid.org/0000-0003-4706-598X, vasyarv@mail.ru*
[d] *ORCID: http://orcid.org/0000-0003-0109-8567, biryukov.vova@gmail.com*

Abstract: in this paper, we solve inverse problems of exploration seismology in rocks with uniformly oriented fractured inclusions using convolutional neural networks. This type of neural network was chosen due to the large dataset. We used simulation to build a neural network training sample from the direct problem results. For the numerical solution of direct problems, a grid-characteristic method was applied to unstructured meshes. This numerical method was used since the studied dynamic processes are of wave nature, which is very suitable for the grid-characteristic method. This approach is proven in building correct computational algorithms for boundary and interface conditions, in particular, for defining discrete fracture arrays. The problem statement is to determine the characteristics of a single fracture and layers of such fractures. The inverse exploration seismology problem for a fractured layer with six unknown parameters was successfully solved. These parameters are the height and angle of inclination of the fractures, the

density of the fractures, the horizontal extent of the formation, and its 2D position. The vibration velocities in the seismic data array and the frequency spectra were inputs for the neural network training and validation sample recognition.

Keywords: machine learning, convolutional neural networks, simulation, grid-characteristic method, seismic survey, inverse problems, fractured media.

Acknowledgements: this work is supported by RFBR, grant No. 20-01-00572.

Cite this article: Muratov M. V., Petrov D. I., Ryazanov V. V., Biryukov V. A. Machine Learning Applications to Solving Inverse Problems in Fractured Layer Seismic Surveys. *Russian Journal of Cybernetics*. 2022;3(1):8–13. DOI: 10.51790/2712-9942-2022-3-1-1.

Введение

Сейсморазведка является одним из наиболее распространенных подходов к изучению геологической структуры грунта без его непосредственного бурения. На поверхности возбуждаются сейсмические волны, которые, взаимодействуя с неоднородностями в геологической среде, образуют отклики, фиксируемые сейсмоприемниками, расположенными на поверхности или в вертикальной скважине. Правильная интерпретация получаемых на сейсмоприемниках сейсмограмм, то есть определение структуры геологического разреза по характеру волнового отклика, является основной задачей сейсморазведки.

Значительный вклад в развитие методик интерпретации сейсмических данных был сделан Дж. Ф. Клаербо [1]. Развитие высокопроизводительных вычислительных систем позволило применить теорию алгоритмов и вычислительных методов для решения практических задач сейсмической разведки [2, 3]. Особый интерес представляет эффективное решение обратных задач. Изначально для вмещающих сред применялась акустическая модель. Существенным недостатком такого подхода было игнорирование значительного объема информации, который несут с собой поперечные волны. В этой связи развитие численного моделирования геологических сред пошло в сторону упругих двухкомпонентных моделей [4].

Новым этапом в решении обратных задач сейсморазведки стало применение методов машинного обучения. К таким методам относятся, в частности, глубокие нейронные сети. В последнее десятилетие они хорошо зарекомендовали себя в таких прикладных областях, как машинный перевод, компьютерное распознавание и генерация речи, анализ текстов, машинное зрение. Во всех перечисленных задачах приходится обрабатывать значительные объемы данных и выявлять связи внутри них. Это также является отличительной особенностью задач сейсморазведки, поэтому сверточные нейронные сети стали использовать и в этой области. Например, при помощи глубокой сверточной нейронной сети решалась двумерная задача поиска разлома [5]. Решению аналогичной задачи в трех измерениях посвящена работа [6]. Примечательно, что при таком подходе практически отсутствует этап специальной обработки входных сейсмических данных, что упрощает его применение по сравнению со стандартными методами.

Одним из основных объектов изучения современной сейсморазведки являются трещиноватые коллекторы. Так как они потенциально могут содержать запасы углеводородов, их поиск является достаточно важной задачей. Данная работа посвящена разработке методики их интерпретации с использованием сверточных нейронных сетей.

Методика решения обратной задачи

Обратная задача сейсморазведки трещиноватого пласта решалась с использованием сверточных нейронных сетей. Обучение нейронной сети проводилось на выборках, сформированных с применением математического моделирования для прямых задач сейсморазведки [7].

Решение прямой задачи

Использовалась модель линейно-упругой среды, система определяющих уравнений которой может быть представлена в виде [8]:

$$\rho\frac{\partial V_i}{\partial t}=\frac{\partial T_{ji}}{\partial x_j}, \qquad \frac{\partial \mathrm{T_{ij}}}{\partial \mathrm{t}}=\lambda\left(\sum_k \frac{\partial V_k}{\partial x_k}\right) I_{ij}+\mu\left(\frac{\partial V_i}{\partial x_j}+\frac{\partial V_j}{\partial x_i}\right), \tag{1}$$

где V_i — компонента скорости, T_{ji} — тензора напряжений, ρ — плотность среды, λ и μ — коэффициенты Ламе, I_{ij} — компонента единичного тензора. Введя вектор переменных $\overrightarrow{u} = \{V_x, V_y, T_{xx}, T_{yy}, T_{xy}\}$, систему (1) приводим к виду:

$$\frac{\partial \overrightarrow{u}}{\partial t} + \sum_{i=1,2} A_i \frac{\partial \overrightarrow{u}}{\partial \xi_i} = 0. \qquad (2)$$

Численное решение (2) находилось с помощью сеточно-характеристического метода [9].

Трещины задавались в области интегрирования дискретно, что позволяло наблюдать более детальную картину волнового отклика, в формировании которого играют роль волновые отражения на каждой трещине пласта, по сравнению с широко применяемыми эффективными моделями трещиноватости [10]. Использовалась концепция бесконечно тонкой трещины, сетка внутри трещины не задавалась, что позволило существенно сократить потребность в вычислительных мощностях для проведения моделирования. Створки трещин представляли собой контактные поверхности со специально разработанными контактными условиями.

Решение обратной задачи

Так как решаемые обратные задачи обладают значительным числом параметров, для распознавания использовалась сверточная нейронная сеть. В результате решения прямых задач были созданы выборки, которые подавались на вход сети в ходе ее обучения. Входной объект представлял собой упорядоченную пару из горизонтальной и вертикальной компоненты скорости сейсмических колебаний. Таким образом, каждый образец мог быть представлен в виде трехмерного объекта, состоящего из компоненты скорости, количества датчиков и количества временных измерений размера (2, 100, 300), то есть — двухкомпонентный образец (2 компоненты скорости).

Данная модель была усовершенствована дополнением объекта обучающей выборки частотным спектром, полученным путем применения преобразования Фурье для временных рядов сейсмограммы. Такой образец стал четырехкомпонентным (две компоненты скорости, две соответствующие частоты), размерности три (4, 100, 300).

Для каждой задачи обучающая выборка была представлена набором из 6000 решений прямых задач. После обучения нейронной сети проводилась ее проверка с использованием валидационной выборки, полученной таким же образом. Проверка проводилась измерением функции потерь (loss-функция), в качестве которой использовалась величина Mean Squared Error (MSE, средняя квадратичная ошибка). В ходе обучения отслеживалась также метрика Mean Absolute Error (MAE, средняя ошибка по модулю). Данные метрики можно использовать как для одномерной величины, так и для многомерных векторов.

$$MAE = \frac{1}{N}\sum_{i=1}^{N} |y_i - \hat{y}|, \qquad MSE = \frac{1}{N}\sum_{i=1}^{N} (y_i - \hat{y})^2.$$

Цель — получить схождение к нулю последовательности значений этих метрик при возрастании эпохи обучения.

Постановка задачи и результаты моделирования

Сначала была рассмотрена модель геологической среды, содержащей одиночную трещину. Рассматривалась однородная упругая среда с размером расчетной области 2 км x 2 км, где скорость продольных волн 4500 м/с, скорость поперечных 2500 м/с, плотность вмещающей среды 2500 кг/м^3 (рисунок 1а). Трещина полагалась субвертикальной с углом наклона ± 15 градусов. Положение варьировалось по обеим координатам в пределах 1 км. Размер трещины изменялся от 50 до 200 м. Сейсмические приемники общим числом 65 единиц располагались равномерно на поверхности, где производилось возбуждение зондирующего импульса. Приемники фиксировали вертикальную и горизонтальную компоненты скорости волн, отразившихся в среде.

Результат изменения функции потерь по метрике MSE для задачи обнаружения одиночной трещины представлен на рисунке 1б. Наблюдается уменьшение значения функционала при увеличении номера эпохи. Таким образом, можно с уверенностью говорить о применимости данного подхода для исследуемых задач.

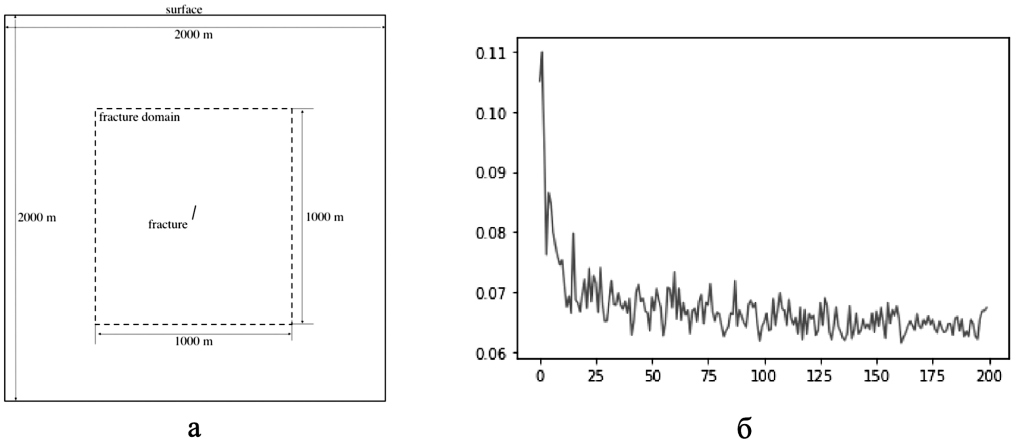


Рис. 1. *Схема расположения одиночной трещины в геологической среде (а), зависимость значения метрики MSE от эпохи обучения (б)*

Далее рассматривалась система (кластер) трещин, залегающая на глубине от 1 до 2 км (рисунок 2). Параметры геологической модели взяты следующие: скорость продольных волн 2250 м/с, скорость поперечных 1250 м/с, плотность 1180 кг/м^3. Сейсмическое возмущение моделировалось волной с плоским фронтом. Расположенные на поверхности 100 сейсмических датчиков с интервалом расстановки 50 метров регистрировали показатели отраженных и рассеянных волн, возникшие после прохождения через кластер трещин.

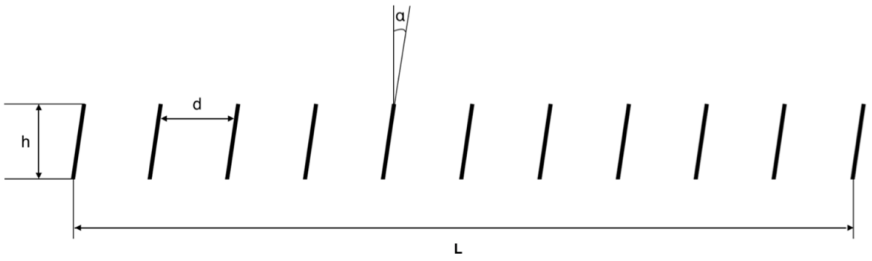


Рис. 2. *Схема кластера однородно ориентированных субвертикальных трещин*

Изменяемыми параметрами являлись: угол наклона (α), высота (h), расстояние между соседними трещинами (d, параметр характеризует плотность расположения трещин), пространственное положение кластера трещин и его горизонтальная протяженность (L). Также рассматривались комбинации параметров: одновременно угол и высота; одновременно угол, высота и расстояние между трещинами; одновременно горизонтальная протяженность, высота и пространственное положение; а также все параметры одновременно.

Сначала данная задача решалась с использованием двухкомпонентного образца выборки (временные ряды горизонтальной и вертикальной компонент отклика). С помощью такого подхода удалось достаточно точно решить задачу с числом варьируемых параметров, не превышающим три. На рисунке 3 представлены графики изменения среднеквадратичных потерь в зависимости от номера эпохи при вариации: угла наклона (а), высоты (б), расстояния между трещинами (в). В данных задачах ошибка распознавания не превышала 10 %.

Для решения обратных задач с большим числом неизвестных параметров рассматривался подход с четырехкомпонентным объектом выборки (временные и частотные ряды горизонтальной и вертикальной компонент отклика). Такой подход дал значительно меньшую ошибку. На рисунке 4 приведено сравнение графиков для MSE в двух представленных походах для вариации угла (а) и высоты (б) трещин.

При вариации сразу шести параметров (высота, угол наклона трещин, их плотность расположения, горизонтальная протяженность и две компоненты пространственного положения) была получена хорошая сходимость значений функционала при росте эпохи обучения. Ошибка не превышала 20 %.

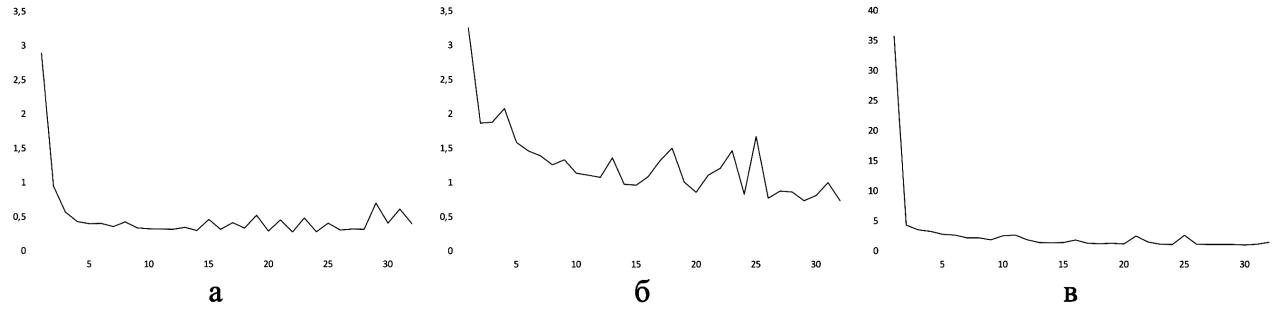


Рис. 3. *Графики зависимости метрики MSE от эпохи обучения при неизвестном угле наклона (а), высоте трещин (б), расстоянии между трещинами (в)*

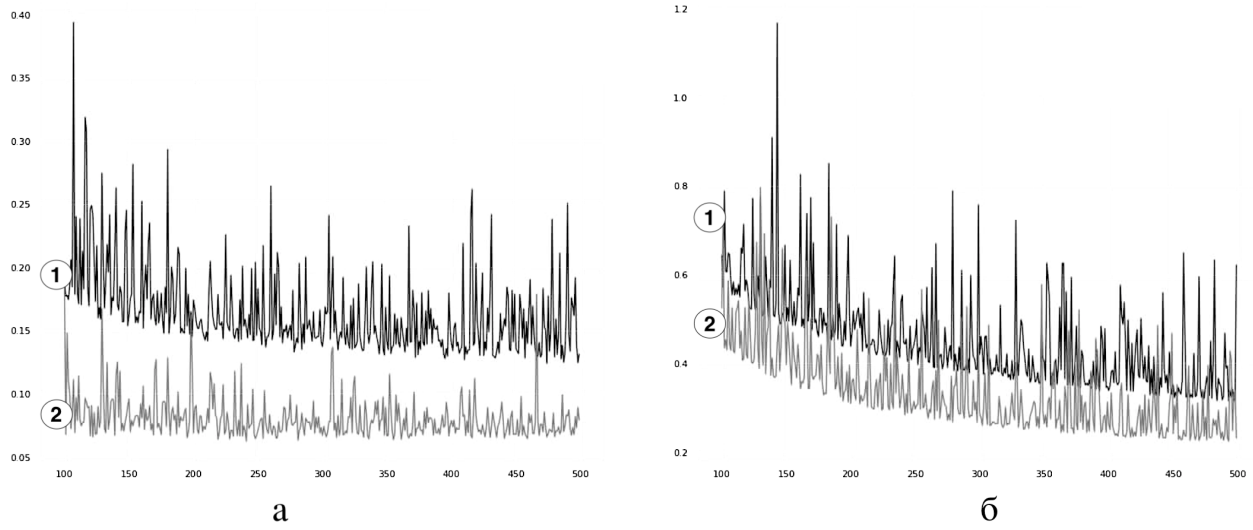


Рис. 4. *Сравнение зависимости метрики MSE от эпохи обучения для двухкомпонентного (1) и четырехкомпонентного (2) объектов выборки для неизвестного угла наклона (а) и высоты трещин (б)*

Заключение

Результаты проведенного исследования свидетельствуют о хорошей применимости методов машинного обучения в задачах обнаружения как одиночных трещин, так и пластов макротрещин. Было рассмотрено использование сверточных нейронных сетей, которые обучались на решениях прямых задач с использованием математического моделирования с применением сеточно-характеристического метода на неструктурированных расчетных сетках.

ЛИТЕРАТУРА

1. Claerbout J. F. Coarse Grid Calculations of Waves in Inhomogeneous Media with Application to Delineation of Complicated Seismic Structure. *Geophysics*. 1970;36(3):407–418.
2. Etgen J., Gray S., Zhang Y. An Overview of Depth Imaging in Exploration Geophysics. *Geophysics*. 2009;74:WCA5–WCA17.
3. Jiao K., Huang W., Vigh D., Kapoor J., Coates R., Starr E. W., Cheng X. Elastic Migration for Improving Salt and Subsalt Imaging and Inversion. *SEG Technical Program Expanded Abstracts*. 2012;1–5.
4. Luo Y., Tromp J., Denel B., Calandra H. 3D Coupled Acoustic-Elastic Migration with Topography and Bathymetry Based on Spectral-Element and Adjoint Methods. *Geophysics*. 2013;78(4):S193–S202.
5. Zhang C., Frogner C., Araya-Polo M., Hohl D. Machine-learning Based Automated Fault Detection in Seismic Traces. *EAGE Conference and Exhibition*. 2014.
6. Araya-Polo M., Dahlke T., Frogner C., Zhang C., Poggio T., Hohl D. Automated Fault Detection without Seismic Processing. *The Leading Edge*. 2017;36(3):194–280.

7. Nikitin I. S., Golubev V. I., Golubeva Y. A., Miryakha V. A. Numerical Comparison of Different Approaches for the Fractured Medium Simulation. *Smart Innovation, Systems and Technologies*. 2021;214:87–99.
8. Новацкий В. К. *Теория упругости*. М.: Мир; 1975. 872 с.
9. Golubev V. I., Shevchenko A. V., Khokhlov N. I., Nikitin I. S. Numerical Investigation of Compact Grid-Characteristic Schemes for Acoustic Problems. *Journal of Physics: Conference Series*. 2021;1902(1):012110.
10. Coates R. T., Shoenberg M. Finite-Difference Modeling of Faults and Fractures. *Geophysics*. 1995;60:1514–1523.