

## ЛОКАЛИЗАЦИЯ МИКРОСЕЙСМИЧЕСКИХ СОБЫТИЙ С ИСПОЛЬЗОВАНИЕМ РЕШЕНИЯ УРАВНЕНИЯ ЭЙКОНАЛА НЕЙРОННОЙ СЕТЬЮ

### *Серафим Игоревич Грубась*

Институт нефтегазовой геологии и геофизики им. А.А. Трофимука СО РАН, 630090, Россия, г. Новосибирск, проспект Академика Коптюга 3, инженер, e-mail: serafimgrubas@gmail.com; Новосибирский государственный университет, 630090, Россия, г. Новосибирск, ул. Пирогова 2, студент.

### *Сергей Владимирович Яскевич*

ИЗК СО РАН, 664033, г. Иркутск, ул. Лермонтова, 128, к.ф.-м.н., старший научный сотрудник, e-mail: YaskevichSV@ipgg.sbras.ru; Новосибирский государственный университет, 630090, Россия, г. Новосибирск, ул. Пирогова 2, старший преподаватель кафедры геофизики.

### *Антон Альбертович Дучков*

Институт нефтегазовой геологии и геофизики им. А.А. Трофимука СО РАН, 630090, Россия, г. Новосибирск, проспект Академика Коптюга, 3, к.ф.-м.н., заведующий лабораторией, e-mail: DuchkovAA@ipgg.sbras.ru; Новосибирский государственный университет, 630090, Россия, г. Новосибирск, ул. Пирогова 2, доцент кафедры геофизики.

В работе продемонстрирован алгоритм использования нейронной сети в процедурах обработки микросейсмических данных применительно к задаче локализации микросейсмических событий. Предложенный алгоритм подразумевает использование нейросетевого решения уравнения эйконала для вычисления времен пробега волн, формирующих первые вступления. В результате, нейросетевое решение сравнивается с наблюдаемыми временами прихода для решения обратной кинематической задачи определения координат положений событий. На синтетическом 3Д примере было показано, что средняя абсолютная ошибка несоответствия времен прихода составила менее 0.25 мс, а средняя ошибка локализации не превысила 4.5 метров.

**Ключевые слова:** уравнение эйконала, нейронная сеть, микросейсмика, локализация

## LOCALIZATION OF MICROSEISMIC EVENTS USING PHYSICS-INFORMED NEURAL NETWORK SOLUTION TO THE EIKONAL EQUATION

### *Serafim I. Grubas*

Trofimuk Institute of Petroleum Geology and Geophysics SB RAS, 630090, Russia, Novosibirsk, 3, Akademika Koptyuga Ave., Engineer, e-mail: serafimgrubas@gmail.com; Novosibirsk State University, 630090, Russia, Novosibirsk, Pirogova st. 2, student

### *Sergey V. Yaskevich*

IEC SB RAS, 664033, Russia, Irkutsk, 3, 128 Lermontova St. 128, PhD, Senior Researcher, e-mail: YaskevichSV@ipgg.sbras.ru; Novosibirsk State University, 630090, Russia, Novosibirsk, Pirogova st. 2, Senior Teacher

### *Anton A. Duchkov*

Trofimuk Institute of Petroleum Geology and Geophysics SB RAS, 630090, Russia, Novosibirsk, 3, Akademika Koptyuga Ave., PhD, Head of Lab, e-mail: DuchkovAA@ipgg.sbras.ru; Novosibirsk State University, 630090, Russia, Novosibirsk, Pirogova st. 2, Associate Professor.

The paper demonstrates an algorithm for using physics-informed neural networks in workflow of processing microseismic data regarding the problem of localization of microseismic events. The proposed algorithm involves the use of a physics-informed neural network solution to the eikonal equation to calculate the traveltimes of the first arrivals. As a result, the network solution is compared with the observed arrival times to solve the inverse kinematic problem to determine the coordinates of the event locations. Using a synthetic 3D example, it was shown that the average absolute error of the arrival time misfit was less than 0.25 ms, and the average localization error did not exceed 4.5 meters.

**Keywords:** eikonal equation, physics-informed neural network, microseismic, localization

## *Введение*

Скважинный микросейсмический мониторинг это важная технология, направленная на наблюдение за слабыми сейсмическими событиями. Наиболее распространенный пример - оценка геометрии трещин гидроразрыва. Эффективность такого метода была продемонстрирована на многочисленных примерах [1], и было показано, что предполагаемые положения сейсмических событий предоставляют инженерам ценные данные для оценки качества работы. Текущее развитие метода частично связано с автоматизацией процедур обработки [2]. В нашей работе, мы предполагаем, что искусственная нейронная сеть (ИНС) будет способствовать ускорению общей обработки и ее применимости в реальном времени. Также мы полагаем, что применяемая ИНС будет работать лучше, если будет применяться на разных этапах обработки: детекция событий, пикировка времен прихода, калибровка скоростной модели, локализация событий. В этой статье мы показываем способ использования ИНС для расчета времен прихода при решении обратной задачи локализации микросейсмических событий.

Для расчета времен прихода сейсмических волн, решают уравнение эйконала, которое является нелинейным дифференциальным уравнением в частных производных (PDE). Существует несколько методов для решения этого уравнения, включая лучевое трассирование [3] и конечно-разностные методы решения [4, 5]. Также есть модификации конечно-разностных методов, в которых для большей точности используется факторизованное уравнение эйконала [6, 7]. Более того, в настоящее время и нейронные сети используются для решения PDE с использованием алгоритмов автоматического дифференцирования (AD), они называются physics-informed neural networks (PINN) [8]. PINN были успешно применены для решения факторизованного уравнения эйконала в прямых задачах [9, 10]. PINN представляют собой решение уравнения эйконала в виде гладкой функции, что может быть полезно для решения обратных задач, таких как сейсмическая томография [11] и вероятностная локализация землетрясений [12]. В нашей статье мы показываем, как PINN решение эйконала может быть использовано в обратной кинематической задаче для локализации микросейсмических событий.

## *Методы и теория*

Уравнение эйконала - это нелинейное дифференциальное уравнение в частных производных, которое описывает времена пробега сейсмических волн в неоднородной скоростной модели:

$$\begin{aligned} \|\nabla_r \tau(\mathbf{x}_s, \mathbf{x}_r)\|^2 &= v(\mathbf{x}_r)^{-2}, \\ \tau(\mathbf{x}_s, \mathbf{x}_s) &= 0, \end{aligned} \quad (1)$$

где  $\|\cdot\|^2$  –  $L_2$  норма,  $\tau(\mathbf{x}_s, \mathbf{x}_r) = \tau(x_s, y_s, z_s, x_r, y_r, z_r)$  – время пробега сейсмической волны от источника  $\mathbf{x}_s$  до приемника  $\mathbf{x}_r$ ,  $\nabla_r = (\partial/\partial x_r, \partial/\partial y_r, \partial/\partial z_r)$  – оператор градиента,  $v(\mathbf{x}_r)$  – значение скорости в среде в точке  $\mathbf{x}_r$ . Здесь,  $\tau$  это функция, которая определяет решение для всех возможных положений источников и приемников в скоростной модели, и нейронная сеть (PINN) попытается найти эту функцию. Мы будем называть функцию  $\tau_\theta$  в качестве PINN-решения уравнения 1, где  $\theta$  – параметры нейронной сети. Кроме того, чтобы избежать ошибок, связанных с большой кривизной решения вокруг сингулярности в точке источника [6, 7], мы используем факторизацию, которая предполагает что искомое решение это отклонение  $\tau'_\theta$  от однородной модели  $v = 1$ :

$$\tau_\theta(\mathbf{x}_s, \mathbf{x}_r) = \|\mathbf{x}_r - \mathbf{x}_s\| \cdot \tau'_\theta(\mathbf{x}_s, \mathbf{x}_r). \quad (2)$$

Факторизация также обеспечивает выполнение граничного условия  $\tau_\theta(\mathbf{x}_s, \mathbf{x}_s) = 0$ , поэтому для обучения PINN будет минимизироваться следующий функционал невязки, содержащий только уравнение:

$$L(\theta) = \frac{1}{N_s N_r} \sum_{i=0}^{N_s} \sum_{j=0}^{N_r} \left[ v(\mathbf{x}_r^j)^2 \|\nabla_r \tau(\mathbf{x}_s^i, \mathbf{x}_r^j)\|^2 - 1 \right]^2 \rightarrow \min_\theta, \quad (3)$$

где  $N_s$  – количество источников,  $N_r$  – количество приемников. После обучения PINN в известной скоростной модели, полученное решение  $\tau_\theta(\mathbf{x}_s, \mathbf{x}_r)$  будет использоваться в решении обратной кинематической задачи для локализации микросейсмических событий. Для этого будет минимизирована следующая невязка для каждого событий отдельно:

$$R(\mathbf{x}_s^i) = \frac{1}{N_r} \sum_{j=0}^{N_r} [\tau_\theta(\mathbf{x}_s^i, \mathbf{x}_r^j) - t_i(\mathbf{x}_r^j)]^2 \rightarrow \min_{\mathbf{x}_s^i} \quad (4)$$

где  $t_i(\mathbf{x}_r^j)$  – наблюдаемое время прихода от  $i$  – го события до приемника  $\mathbf{x}_r^j$ . Преимущество использования PINN здесь заключается в том, что функцию  $\tau_\theta(\mathbf{x}_s, \mathbf{x}_s)$  можно легко дифференцировать по  $\mathbf{x}_s$ .

### ***Численный эксперимент и результаты***

Мы протестировали предложенный подход на слоистой модели с четырьмя однородными слоями (рис. 1) со значениями скорости продольных волн [2.88, 2.75, 2.8, 2.4] км/с и границы слоев на глубинах [3.11, 3.16, 3.21] км. Предвари-

тельно, мы решаем уравнение 1, используя PINN в области  $x \in [-0.6, 0.3]$  км,  $y \in [-0.3, 0.4]$  км,  $z \in [2.9, 3.4]$  км, при этом источники  $\mathbf{x}_s$  и приемники  $\mathbf{x}_r$  были равномерно распределены с шагами  $[\Delta x_s, \Delta y_s, \Delta z_s] = [0.09, 0.07, 0.02]$  км и  $[\Delta x_r, \Delta y_r, \Delta z_r] = [0.045, 0.035, 0.01]$  км соответственно. В результате, общее количество точек для решения уравнения эйконала составляет  $N_s \cdot N_r = 2541 \cdot 18081 \approx 46 \cdot 10^6$ . Невязка была минимизирована с помощью адаптивного градиентного спуска Adam [13]. Кроме того, мы использовали улучшенную полносвязную нейронную архитектуру PINN [14], которая содержит 6 скрытых слоев, 100 единиц на каждом слое и локально адаптивный гиперболический тангенс [15] в качестве функции активации.

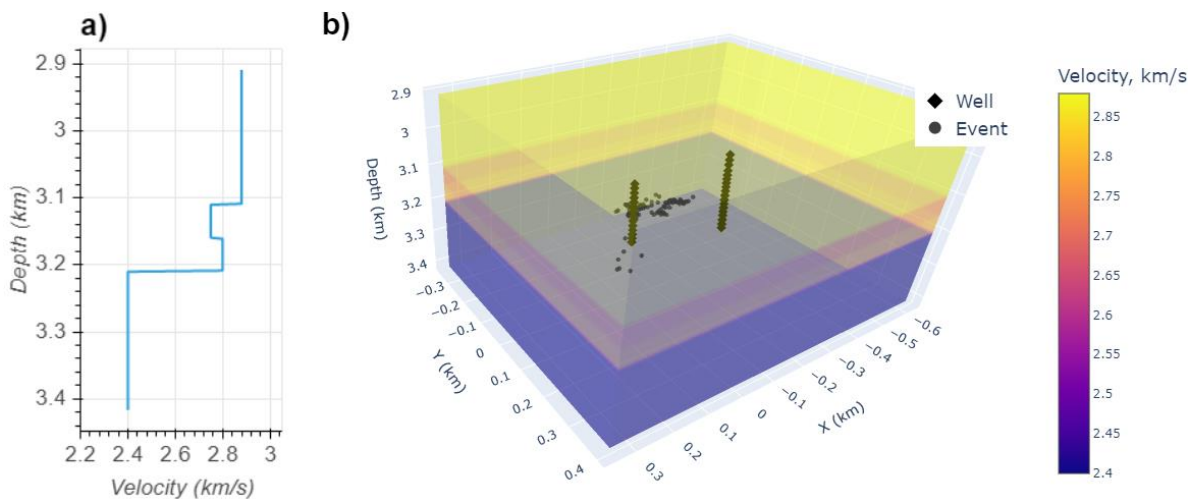


Рис. 1. Вертикально-слоистая скоростная модель и геометрия наблюдательных скважин и микросейсмических событий. **a** – вертикальный профиль скоростной модели, **b** – трехмерное представление модели и геометрии, где цвет отображает значения скорости, черные ромбики – местоположения приемников в наблюдательных скважинах, черные кружки соответствуют истинным местоположениям событий

Мы обучали PINN 15 эпох. Результирующее значение функционала невязки 3 (среднеквадратичная ошибка) составило около  $10^{-4}$  с. Обученная PINN дает время первых вступлений и будет использоваться, как дифференцируемая функция для локализации микросейсмических событий.

Для подготовки синтетических данных  $t_i(\mathbf{x}_r^j)$  мы использовали лучевое трассирование в слоистых изотропных средах. В этом случае, для вычисления времен прихода используется информация о типе волны, при этом предполагается, что мы работаем только с прямой волной. Алгоритм находит лучи, удовлетворяющие принципу Ферма. Подробно система наблюдений представлена на рисунке 2, она включает в себя две субвертикальные мониторинговые скважины, в том числе 14 и 18 приемников, длина апертуры приемников составляет примерно 170 и 270 м. Микросейсмическое облако включает 103 события, и боль-

шинство из них образует ограниченный объем с сублинейной геометрией. Скважины для мониторинга неравномерно удалены от облака микросейсмических событий, более короткая скважина находится на расстоянии 150 м, а более длинная скважина - примерно в 300 м. Чтобы определить местонахождение этих микросейсмических событий, мы минимизировали невязку 4 для каждого события, используя алгоритм Adam. Средняя абсолютная ошибка времен пробега PINN  $\tau_\theta$  и предсчитанных  $t$  не превышает 0.25 мс, а средняя ошибка определения гипоцентров - менее 4.5 м. Геометрия микросейсмического облака (см. рис. 2) восстановлена корректно.

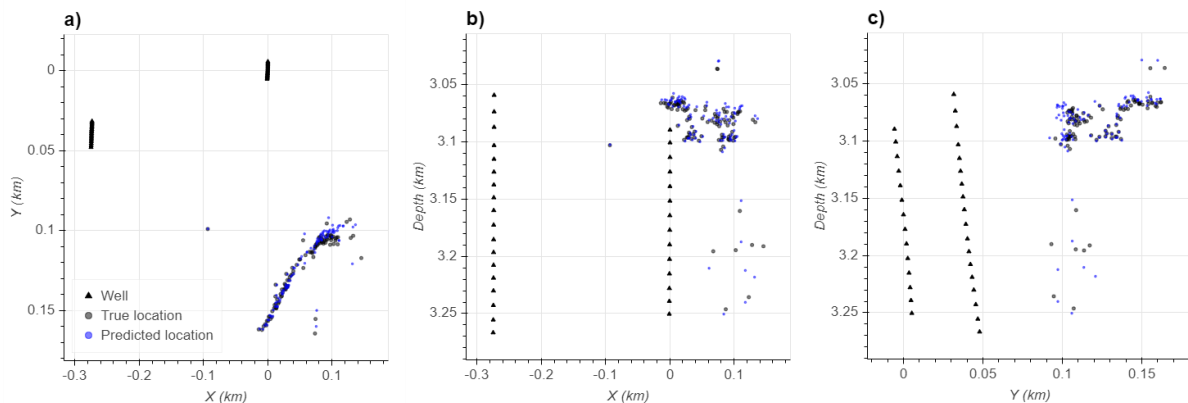


Рис. 2. Результаты локализации в разных проекциях: **а** - плоскость XY, **б** - плоскость XZ, **с** - плоскость YZ. Черные треугольники – местоположения приемников, черные кружки – реальные положения событий, синие кружки – результаты локализации с использованием решения PINN

### *Заключение*

Мы показали пример использования нейронной сети в процедурах обработки микросейсмических данных. Мы выполнили локализацию микросейсмических событий с помощью обученной нейронной сети, которая являлась решением уравнения эйконала и использовалась для вычисления времени пробега. В результате, средняя абсолютная ошибка по невязке времен пробега составила менее 0.25 мс, а средняя ошибка локализации не превысила 4.5 метров.

### *Обсуждение и ограничения метода*

Мы продемонстрировали, как нейронная сеть, представляющая решение уравнения эйконала, может быть использована для решения обратной кинематической задачи, когда известна скоростная модель. Однако в реальных случаях скоростная модель известна лишь частично. Тем не менее, предложенный подход может быть дополнен дополнительной нейронной сетью, которая выполняет коррекцию скоростной модели в соответствии с уравнением эйконала и наблюдаемыми временами прихода.

Кроме того, мы не учли одно возможное ограничение, связанное с приходом головных волн. Обычно, при обработке скважинных микросейсмических данных наблюдаемые волны считаются прямыми волнами, и для многих скоростных моделей эти волны образуют первые вступления. Редко наблюдаются приходы головных волн с гораздо меньшими амплитудами, чем прямые, что означает, что в некоторых случаях фаза головных волн будет полностью замаскирована шумом и их невозможно будет выделить, в то время как PINN всегда дает время прихода первых вступлений, т. е. включая и приходы головных волн. Можно видеть два примера из нашего численного эксперимента на рис. 3.a и рис. 3.b. Первое связано с обычным событием, когда головной волны нет, и времена пробега совпадают почти идеально. С другой стороны, второй рисунок показывает, как PINN пыталась подогнать приходы головных волн к наблюдаемым временам пробега прямых волн, что может вносить систематическое смещение в локализацию событий.




Рис. 3. Наблюдаемые времена прихода и рассчитанные PINN. **a** показывает времена прихода для события без головных волн, **b** показывает времена прихода, когда головная волна присутствует в первых вступлениях, черные прямоугольники представляют зоны с несоответствием.

*Работа частично поддержана проектом фундаментальных исследований 0331-2019-0009.*

#### БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Rutledge J. T., Phillips W. S. Hydraulic stimulation of natural fractures as revealed by induced microearthquakes, Carthage Cotton Valley gas field, east Texas Hydraulic Stimulation of Natural Fractures // *Geophysics*. – 2003. – V. 68. – №. 2. – P. 441-452.
2. Hogarth L. J., Kolb C. M., Le Calvez J. H. Controlled-source velocity calibration for real-time downhole microseismic monitoring // *The Leading Edge*. – 2017. – V. 36. – №. 2. – P. 172-178.
3. Červený V., Klimeš L., Pšeničák I. Paraxial ray approximations in the computation of seismic wavefields in inhomogeneous media // *Geophysical Journal International*. – 1984. – V. 79. – №. 1. – P. 89-104.
4. Sethian J. A. A fast marching level set method for monotonically advancing fronts // *Proceedings of the National Academy of Sciences*. – 1996. – T. 93. – №. 4. – C. 1591-1595.

5. Zhao H. A fast sweeping method for eikonal equations // *Mathematics of computation*. – 2005. – V. 74. – №. 250. – P. 603-627.
6. Fomel S., Luo S., Zhao H. Fast sweeping method for the factored eikonal equation // *Journal of Computational Physics*. – 2009. – V. 228. – №. 17. – P. 6440-6455.
7. Treister E., Haber E. A fast marching algorithm for the factored eikonal equation // *Journal of Computational physics*. – 2016. – V. 324. – P. 210-225.
8. Raissi M., Perdikaris P., Karniadakis G. E. Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations // *Journal of Computational Physics*. – 2019. – V. 378. – P. 686-707.
9. Smith J. D., Azizzadenesheli K., Ross Z. E. Eikonet: Solving the eikonal equation with deep neural networks // *IEEE Transactions on Geoscience and Remote Sensing*. – 2020.
10. Waheed U. et al. A holistic approach to computing first-arrival traveltimes using neural networks // *arXiv preprint arXiv:2101.11840*. – 2021.
11. Waheed U. et al. PINNtomo: Seismic tomography using physics-informed neural networks // *arXiv preprint arXiv:2104.01588*. – 2021.
12. Smith J. D. et al. HypoSVI: Hypocenter inversion with Stein variational inference and Physics Informed Neural Networks // *arXiv*. – 2021.
13. Kingma D. P., Ba J. Adam: A method for stochastic optimization // *arXiv preprint arXiv:1412.6980*. – 2014.
14. Wang S., Teng Y., Perdikaris P. Understanding and mitigating gradient pathologies in physics-informed neural networks // *arXiv preprint arXiv:2001.04536*. – 2020.
15. Jagtap A. D., Kawaguchi K., Em Karniadakis G. Locally adaptive activation functions with slope recovery for deep and physics-informed neural networks // *Proceedings of the Royal Society A*. – 2020. – V. 476. – №. 2239. – P. 20200334.

© С. И. Грубасъ, С. В. Яскевич, А. А. Дучков, 2021