

ИНФОРМАТИКА

Известия Саратовского университета. Новая серия. Серия: Математика. Механика. Информатика. 2026. Т. 26, вып. 1. С. 106–131

Izvestiya of Saratov University. Mathematics. Mechanics. Informatics, 2026, vol. 26, iss. 1, pp. 106–131

<https://mmi.sgu.ru>

DOI: <https://doi.org/10.18500/1816-9791-2026-26-1-106-131>

EDN: <https://elibrary.ru/RCZMNH>

Обзорная статья

УДК 550.834

Описание существующих подходов к автоматизации определения первых вступлений на сейсмических трассах

Г. Е. Бурцев^{1,2✉}, М. М. Немирович-Данченко¹

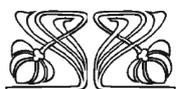
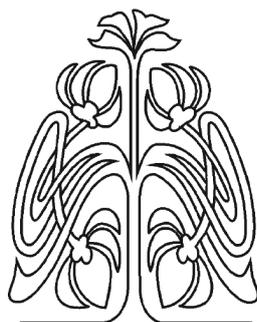
¹Томский государственный университет систем управления и радиоэлектроники, Россия, 634050, г. Томск, просп. Ленина, д. 40

²АО «ТомскНИПИнефть», Россия, 634027, г. Томск, просп. Мира, д. 72

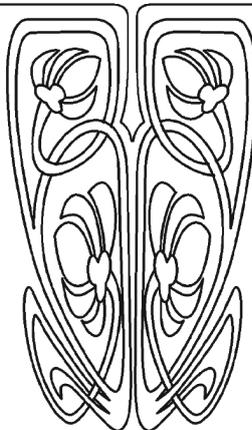
Бурцев Григорий Евгеньевич, ¹аспирант кафедры комплексной информационной безопасности электронно-вычислительных систем; ²инженер отдела сейсморазведочных работ, Grigory.E.Burtsev@outlook.com, <https://orcid.org/0009-0004-7022-3215>, SPIN: 7734-5460, AuthorID: 1264748

Немирович-Данченко Михаил Михайлович, доктор физико-математических наук, профессор кафедры комплексной информационной безопасности электронно-вычислительных систем, mmm@fb.tusur.ru, <https://orcid.org/0000-0002-4510-8045>, SPIN: 6352-4670, AuthorID: 7498

Аннотация. Для обработки зарегистрированных исходных сейсмических сигналов требуется предварительно определить в них моменты времени первых вступлений полезной информации. В статье приводятся сведения обзорного вида о существующих подходах к автоматизации определения первых вступлений волн в сейсмических сигналах, разделяемых данными вступлениями на область шумов-микросейсм и на область полезных данных. Все описываемые подходы к пикированию вступлений в статье разделены на два вида: с использованием нейронных сетей и классические подходы без нейронных сетей, при этом нейронные сети могут включать в себя классические подходы. Также с течением времени по мере развития информационных технологий и вычислительной техники установлен рост количества публикаций по теме автоматического обнаружения первых вступлений, в которых используются машинное обучение и нейронные сети. К классическим подходам к пикированию отнесены пороговый алгоритм, *STA/LTA*-алгоритм оценки фрактальной размерности, расчет статистики более высокого порядка, авторегрессионный подход, пикирование с накопительным фильтром, корреляционный подход, алгоритм динами-



Научный
отдел





ческого искривления времени, нечеткая кластеризация. К нейросетевым подходам отнесены полносвязные нейронные сети, нейронные сети Кохонена, сверточные нейронные сети. Краткое описание каждого подхода приводится в тексте статьи с указанием ссылок-источников для получения более подробной информации о подходе при необходимости. В заключении статьи приводится обобщающая схема существующих подходов к автоматическому пикированию первых вступлений с таблицей полученных значений точности пикировок авторами исследований.

Ключевые слова: первые вступления сейсмических волн, автоматическое пикирование первых вступлений, микросейсмы, машинное обучение, нейронные сети

Для цитирования: Бурцев Г. Е., Немирович-Данченко М. М. Описание существующих подходов к автоматизации определения первых вступлений на сейсмических трассах // Известия Саратовского университета. Новая серия. Серия: Математика. Механика. Информатика. 2026. Т. 26, вып. 1. С. 106–131. DOI: <https://doi.org/10.18500/1816-9791-2026-26-1-106-131>, EDN: RCZMNH

Статья опубликована на условиях лицензии Creative Commons Attribution 4.0 International (CC-BY 4.0)

Review

The description of approaches to seismic waves automatic first breaks picking

G. Ye. Burtsev^{1,2✉}, M. M. Nemirovich-Danchenko¹

¹Tomsk State University of Control Systems and Radioelectronics, 40 prospect Lenina, Tomsk 634050, Russia

²JSC TomskNIPIneft, 72 Mira Ave., Tomsk 634027, Russia

Grigory Ye. Burtsev, Grigory.E.Burtsev@outlook.com, <https://orcid.org/0009-0004-7022-3215>, SPIN: 7734-5460, AuthorID: 1264748

Mikhail M. Nemirovich-Danchenko, nmm@fb.tusur.ru, <https://orcid.org/0000-0002-4510-8045>, SPIN: 6352-4670, AuthorID: 7498

Abstract. It is necessary to determine seismic wave first breaks before the following processing of initial field seismic data is done. These first breaks separate seismic signals into two parts: microseismic noise and a useful information part. In the paper the authors present the overview information about the existing approaches aimed at automatic first breaks detection. All the described first break picking approaches are separated into two types: the one that uses neural networks and the other one that composes the classic approaches without using neural networks. Meanwhile, neural network-based approaches could include the classic ones in themselves. It was found out that nowadays the neural network-based approaches prevail with the dominating quantity of scientific publications on the topic. The authors classify the classic approaches into the threshold algorithm, the *STA/LTA* fractal dimension estimation algorithm, the higher-order statistics calculation algorithm, the autoregressive algorithm, the filter picker algorithm, the correlative approach, the dynamic time warping algorithm and the fuzzy clusterisation algorithm. The neural network approaches include fully connected dense networks, Kohonen networks and convolutional networks. The brief description of each approach is given in the paper, providing references for a reader to be able to get more information if needed. In conclusion, the authors provide a general scheme summarising considered automatic first break picking approaches. The accuracy table achieved by those methods is also provided.

Keywords: seismic wave first breaks, automatic first break picking, microseisms, machine learning, neural networks

For citation: Burtsev G. Ye., Nemirovich-Danchenko M. M. The description of approaches to seismic waves automatic first breaks picking. *Izvestiya of Saratov University. Mathematics. Mechanics. Informatics*, 2026, vol. 26, iss. 1, pp. 106–131 (in Russian). DOI: <https://doi.org/10.18500/1816-9791-2026-26-1-106-131>, EDN: RCZMNH

This is an open access article distributed under the terms of Creative Commons Attribution 4.0 International License (CC-BY 4.0)



Введение

Обработка исходных данных наземной сейсморазведки методом общей глубинной точки требует введения статических поправок для учета неровностей рельефа и влияния низкоскоростной верхней части разреза (ВЧР) путем временного сдвига записанных сейсмических трасс к общему уровню приведения. Качество введения данной поправки зависит от точности определения времен первых вступлений сейсмических волн [1]. Отделение области шумов на регистрируемых сигналах от области полезной части сигнала представляет собой непростую задачу, для решения которой исследователями разработаны и применяются различные методы.

Пикирование первых вступлений вручную геофизиком является чрезвычайно трудоемкой задачей, особенно в случае обработки данных 3D сейсморазведки [2]. Предприятия нефтегазодобывающей отрасли стремятся снизить количество часов трудозатрат, требуемых для обработки сейсмических данных, по этой причине автоматизация пикирования первых вступлений сейсмических волн является крайне актуальной проблемой в этой сфере.

Цель данной статьи — ознакомить читателя с разработанными исследователями способами автоматического определения первых вступлений на исходных сейсмических данных.

Многие рассматриваемые здесь методы могут быть применены не только к сейсмическим данным, акцент делается именно на применении этих методов к сейсмическим сигналам. Описываемые способы автоматического пикирования имеют различную природу. Некоторые основаны исключительно на априорной информации о форме регистрируемого сигнала, иные требуют применения машинного обучения, в том числе построения нейронных сетей.

Алгоритмы, не применяющие нейронные сети, в статье названы классическими и рассматриваются отдельно в первой ее части. Вторая часть посвящена подходам к пикированию вступлений с применением нейронных сетей. При этом и в случае нейросетевого подхода классические алгоритмы не теряют своей значимости, так как могут быть включены в состав комплексных систем пикирования, совмещающих их с применением нейронных сетей. Анализ работ по автоматическому пикированию первых вступлений позволяет выделить следующие алгоритмы, методы и подходы, отнесенные к классическим: пороговый (п. 1.1), *STA/LTA*-алгоритм оценки фрактальной размерности (п. 1.2), расчет статистики более высокого порядка (п. 1.3), авторегрессионный подход (п. 1.4), алгоритм пикирования с накопительным фильтром (*FilterPicker*) (п. 1.5), корреляционный подход (п. 1.6), алгоритм динамического искривления времени (*DTW*) (п. 1.7), алгоритм нечеткой кластеризации методом *k*-средних (*FCM*) (п. 1.8). Подходы с применением нейронных сетей для решения задачи отделения шумов-микросейсмов от полезного сигнала в настоящем обзоре классифицированы по фундаментальному принципу их работы. Среди нейросетевых подходов выделены следующие: подход с применением полносвязных нейронных сетей (п. 2.1), применение нейронных сетей Кохонена (п. 2.2), сверточные нейронные сети (*CNN*) (п. 2.3).

1. Классические алгоритмы без применения нейронных сетей

1.1. Пороговый алгоритм

Алгоритм, именуемый пороговым, является наипростейшим [3]. Он отделяет полезную часть сигнала от шумовой части по простому принципу превышения сигналом некоторого заранее заданного порогового значения и хорошо себя показывает в случае низкозашумленных данных [4]. Схема работы алгоритма приведена на рис. 1.

Вместо простого порога в алгоритме может применяться среднееквадратичное значение, вычисленное в некотором коротком временном окне. Такой вариант алгоритма менее чувствителен к пиковидным помехам в исходном сигнале [3].



1.2. STA/LTA-алгоритм оценки фрактальной размерности

Данный алгоритм впервые был представлен Алленом в 1978 г. (см. [5]). В нем вместо порогового значения вычисляется отношение среднего короткопериодного характеристического значения амплитуд сигнала к длиннопериодному среднему значению (*STA/LTA*) [1]. Алгоритм непрерывно вычисляет средние характеризующие сейсмический сигнал значения в двух скользящих временных окнах. Короткое окно призвано реагировать на приход полезной сейсмической информации в сигнале, а длинное окно преимущественно содержит в себе информацию о регистрируемых приемником микросейсмах [3].

Согласно алгоритму требуется рассчитать характеристическую функцию *CF*, задаваемую выражением [6]:

$$CF_i = x_i^2 + C_i \times \dot{x}_i^2, \quad (1)$$

где \dot{x}_i — первая производная сигнала по времени, C_i — взвешивающая константа, определяемая уравнением

$$C_i = \frac{\sum_{j=i-W_{TA}+1}^i |x_j|}{\sum_{j=i-W_{TA}+1}^i |\dot{x}_j|},$$

где W_{TA} — длина временного окна, при этом $1 \leq W_{TA} \leq i$, $|x_j|$ — абсолютное значение первой дискретной производной сигнала по времени, определяемое выражением

$$|\dot{x}_j| = |x_j - x_{j-1}|.$$

Выражения для *STA* и *LTA* записываются соответственно как [7,8]

$$STA_i = \frac{1}{W_{STA}} \times \sum_{j=i-W_{STA}+1}^i CF_j,$$

$$LTA_i = \frac{1}{W_{LTA}} \times \sum_{j=i-W_{LTA}+1}^i CF_j,$$

где W_{STA} — длина короткого временного окна и W_{LTA} — длина длинного временного окна, при этом выполняются условия $1 \leq W_{STA} \leq i$ и $1 \leq W_{LTA} \leq i$. Данные окна схематично изображены на рис. 2.

По росту значений отношения λ_i , определяемого выражением $\lambda_i = \frac{STA_i}{LTA_i}$, можно отделить область шума от области полезного сигнала [7,9].

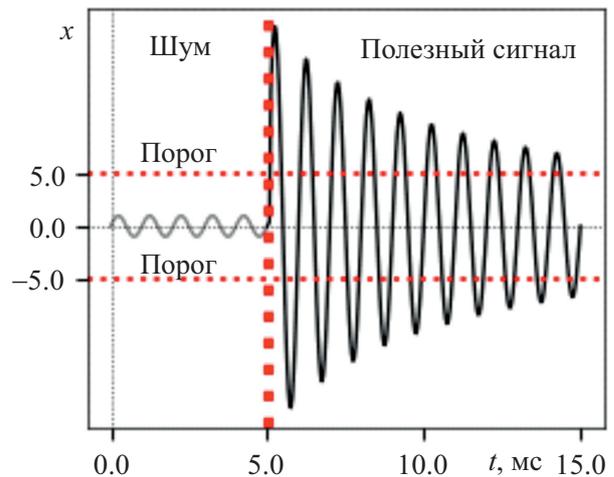


Рис. 1. Схема срабатывания порогового алгоритма при достижении абсолютной амплитудой x сигнала заранее заданного порогового значения (+5.0 и -5.0) в момент времени первых вступлений $t_0 = 5$ мс (цвет онлайн)

Fig. 1. The scheme of the threshold algorithm triggering with a signal amplitude x reaching the given threshold value (+5.0 and -5.0) when the first breaks are registered at time $t_0 = 5$ ms (color online)

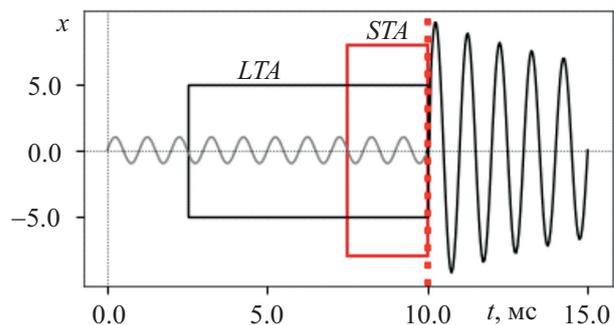


Рис. 2. Изображение короткого (*STA*) и длинного (*LTA*) временных окон с временем прихода первых вступлений $t_0 = 10$ мс (цвет онлайн)

Fig. 2. The scheme of the short (*STA*) and long (*LTA*) time windows with first breaks time $t_0 = 10$ ms (color online)

Для повышения чувствительности алгоритма к изменениям высокочастотных компонентов сигнала вместо исходного сигнала $x(t)$ можно использовать его первую и вторую производные по времени $\dot{x}(t)$ и $\ddot{x}(t)$ [10]. Также вместо выражения (1) для определения характеристической функции CF разными авторами в работах [11, 12] были предложены иные варианты, задаваемые одним из уравнений:

$$\begin{aligned} CF_i &= |x_i|, \\ CF_i &= |x_i^2|, \\ CF_i &= \sqrt{x_i^2 + h^2(x_i)}, \end{aligned}$$

где $h(x_i)$ — значение преобразования Гильберта сигнала в момент времени i -го семпла.

Характеристическая функция, основанная на расчете среднего по k ближайшим семплам-соседям, представлена в работе [8]. Для каждого семпла находятся k его ближайших семплов-соседей по формуле

$$d_{i,j} = |x_i - x_j|, \quad i, j = 1, \dots, n,$$

где $d_{i,j}$ — евклидово расстояние между двумя семплами i и j сигнала $x(t)$, n — общее число семплов данных в сигнале.

Затем вычисляется характеристическая функция CF по формуле

$$CF_i = \frac{1}{k} \sum_{q=1}^k d_{i,j}^{(q)},$$

где $d_{i,j}^{(q)}$ — q -е расстояние от i -го семпла до очередного ближайшего соседа, k — общее количество найденных для i -го семпла ближайших соседей.

Бэр и Крадольфер модифицировали алгоритм Аллена в 1987 г. (см. [6]). Ими было предложено охарактеризовать сигнал при помощи огибающей функции $E(i)$, которая вычисляется по формуле

$$E_i = x_i^2 + \dot{x}_i^2 \frac{\sum_{j=i_w}^i (x_j^2)}{\sum_{j=i_w}^i (\dot{x}_j^2)}, \quad (2)$$

где $i_w = i - W_{TA} + 1$, при этом $1 \leq W_{TA} \leq i$. Тогда характеристическая функция CF может быть найдена как

$$CF_i = \frac{E_i^2 - \overline{E_i^2}}{\sigma^2(E_i^2)}, \quad (3)$$

где $\overline{E_i^2}$ — среднее значение квадрата огибающей функции на временном окне заданной длины W_{TA} , $\sigma(E_i^2)$ — среднеквадратическое отклонение квадрата огибающей функции на том же временном окне [6].

1.3. Расчет статистики более высокого порядка

Данный подход похож на модифицированный Бэром и Крадольфером алгоритм STA/LTA , но вместо расчета характеристической функции CF по формулам (2) и (3) и отношения STA/LTA в нем во временном окне применяется расчет дисперсии и коэффициентов асимметрии и эксцесса [13, 14]. В этом алгоритме предполагается, что в области микросейсм-ов регистрируемый сигнал представляет собой гауссовый шум и подчиняется нормальному закону распределения [14]. При попадании момента времени регистрации первых вступлений t_0 в скользящее временное окно сейсмический сигнал в нем теряет вид нормально распределенного.

Центральный статистический момент m_k порядка k определяется выражением [6]

$$m_k = E[(X - E[X])^k], \quad k > 1,$$



где $E[X]$ — математическое ожидание вектора X , состоящего из семплов x_i сейсмического сигнала $x(t)$, которые попадают во временное окно заданной длины W_{TA} .

Коэффициент асимметрии S вычисляется по формуле [6]

$$S = \frac{E[(X - E[X])^3]}{(E[(X - E[X])^2])^{3/2}} = \frac{m_3}{m_2^{3/2}}, \quad (4)$$

а коэффициент эксцесса K — по формуле [6]

$$K = \frac{E[(X - E[X])^4]}{(E[(X - E[X])^2])^2} = \frac{m_4}{m_2^2}. \quad (5)$$

Коэффициент S равен нулю в случае симметричной функции плотности распределения, например в случае нормального распределения. Данный коэффициент становится отрицательным, если функция плотности распределения более пологая слева, и положительным в противном случае [6]. Коэффициент эксцесса K равен нулю для случая нормального распределения. Сигнал именуется надгауссовым, если его значения с большей вероятностью располагаются в окрестности математического ожидания по сравнению с нормальным законом распределения при одних и тех же значениях математического ожидания и дисперсии. В противном случае, если значения, принимаемые сигналом, с большей вероятностью будут находиться на большем удалении от математического ожидания сигнала по сравнению с нормальным законом распределения, сигнал именуется подгауссовым [15]. Коэффициент эксцесса характеризует длину хвостов функции плотности распределения вправо и влево от ее математического ожидания. На рис. 3 представлен общий вид функций, характеризующих коэффициенты асимметрии (4) и эксцесса (5) некоторого синтетического сейсмического сигнала, которые были посчитаны во временном окне определенной длины W_{TA} . Далее к этим значениям может быть применен простой пороговый алгоритм, описанный в п. 1.1 этой статьи. Длину временного окна и пороговое значение необходимо подбирать экспериментально.

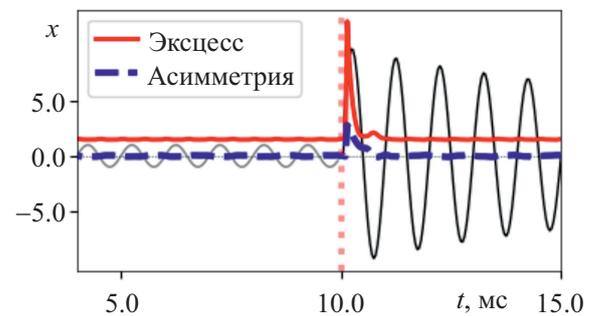


Рис. 3. Общий вид рассчитанных на определенном временном окне W_{TA} функций, характеризующих коэффициенты эксцесса K и асимметрии S некоторого сейсмического сигнала $x(t)$. Время $t_0 = 10$ мс — момент прихода первых вступлений (цвет онлайн)

Fig. 3. The general view of excess K and asymmetry S coefficients graphs within a time window W_{TA} of a seismic signal $x(t)$. $t_0 = 10$ ms is the time of a seismic signal first breaks (color online)

1.4. Авторегрессионный подход

В данном подходе при помощи авторегрессионной модели, рассчитанной во временном окне W_{TA} , оценивается предполагаемое значение сигнала в будущий момент времени [16]. Значения сигнала $x(t)$ выражаются в виде авторегрессионной функции AR [6, 16]:

$$X_t = \sum_{m=1}^p b_m X_{t-m} + \varepsilon_t, \quad (6)$$

где X_t — вектор, состоящий из семплов сигнала $x(t)$; b_m — коэффициенты авторегрессии, определяемые методом наименьших квадратов; ε_t — ошибка предсказания истинного значения сигнала моделью, которая характеризует в данном подходе белый шум в области

микросейсмиков [6]. Для адекватной работы функции авторегрессии AR требуется выполнить подбор подходящего значения порядка авторегрессии p [16]. В работе [16] применяется порядок $p = 4$. Характеристическая функция CF в таком случае трактуется как ошибка ε_t предсказания истинной волновой формы из выражения (6) [16]. По внезапному росту ошибки предсказания ε_t можно заключить, что сейсмический сигнал вышел из области белого шума и приемником был зарегистрирован полезный сейсмический сигнал.

Дальнейшее развитие идеи предсказания вступлений при помощи авторегрессионной модели AR привело к появлению модернизированной модели авторегрессии $AR-AIC$. Пусть сигнал до регистрации вступлений $x_n^{(1)}(t)$ описывается авторегрессионной моделью AR

$$x_n^{(1)} = \sum_{m=1}^M b_i^{(1)} x_{n-m} + \varepsilon_n^{(1)},$$

а после первых вступлений сигнал $x_n^{(2)}(t)$ описывается моделью AR , задаваемой уравнением [6, 17–19]

$$x_n^{(2)} = \sum_{m=1}^L b_i^{(2)} x_{n-m} + \varepsilon_n^{(2)},$$

где $b_i^{(1)}$ и $b_i^{(2)}$ — коэффициенты AR для двух областей сигнала до и после первых вступлений в момент t_0 , $\varepsilon_n^{(1)}$ и $\varepsilon_n^{(2)}$ — соответствующие ошибки предсказания сигналов $x_n^{(1)}$ и $x_n^{(2)}$ моделями AR . Значения M и L задают ширину окон расчета AR для сигналов $x_n^{(1)}$ и $x_n^{(2)}$ соответственно. В модели $AR-AIC$ применяется информационный критерий Акаике (AIC) [14, 20, 21]

$$AIC(k) = AIC_1 + AIC_2, \tag{7}$$

где AIC_1 и AIC_2 — два информационных критерия, каждый из которых соответствует своему сегменту сигнала. AIC_1 соответствует области до регистрации первых вступлений, т.е. белому шуму, а AIC_2 соответствует области сигнала после первых вступлений. Каждый из сегментов описывается при помощи авторегрессионной модели. Минимум функции $AIC(k)$ соответствует времени регистрации первых вступлений t_0 . Если точка k разделяет исходный

сигнал на два сегмента, то выражение (7) записывается в виде [6, 19]

$$AIC(k) = (k - M) \lg(\sigma_1^2(x_{M+1, \dots, k})) + (n - k - M) \lg(\sigma_2^2(x_{k+1, \dots, n-M})) + C_1, \tag{8}$$

где M — параметр, определяющий длину двух окон, характеризующих две области сигнала AIC_1 и AIC_2 , который требуется подобрать перед началом вычислений [22]. В выражении (8) длина этих двух окон принимается одинаковой. $\sigma_1(x_{M+1, \dots, k})$ и $\sigma_2(x_{k+1, \dots, n-M})$ — среднеквадратичные отклонения сигнала $x(t)$ в двух областях — AIC_1 и AIC_2 соответственно, C_1 — константа. В общем виде функция $AIC(k)$ из выражения (7) для некоторого синтетического сигнала представлена на рис. 4.

В работе [23] авторами с целью устранения ложного срабатывания данного алгоритма на пиковидные ошибки в записанном

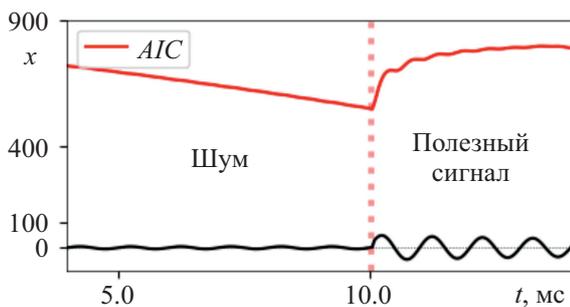


Рис. 4. Общий вид функции, представляющей информационный критерий Акаике AIC для некоторого сейсмического сигнала $x(t)$. Время $t_0 = 10$ мс — момент прихода первых вступлений, определяемый минимальным значением функции AIC (цвет онлайн)

Fig. 4. Akaike information criterion function AIC general view for some seismic signal $x(t)$. Time $t_0 = 10$ ms is the first break time moment determined by the minimum value of function AIC (color online)



исходном сигнале предлагается сигнал $x(t)$ предварительно пропускать через медианный фильтр для устранения шумов в нем, затем выполнять поиск минимума функции $AIC(k)$ с дополнительной проверкой отношения максимальной амплитуды всего сигнала $x(t)$ к амплитуде первого экстремума сигнала после найденного вступления. Если это значение не меньше, чем предварительно заданное число β , найденное вступление принимается за истинное. В противном случае срабатывание алгоритма принимается ложным.

1.5. Пикирование с накопительным фильтром (*FilterPicker*)

Данный алгоритм был специально разработан для работы в системах реального времени [5]. Сигнал $x(t)$, подаваемый на вход алгоритма, может быть представлен как в исходном виде, так и быть подвергнут некоторой предобработке. В основе работы алгоритма лежат простые логические и арифметические операции, без экспонент и логарифмов, что определяет его вычислительную эффективность [10].

Исходный дискретный сигнал $x(t)$ преобразуется в некоторый усредняющий вектор значений x_{long} [10]:

$$x_{long_i} = C_{long}x_{long_{i-1}} + (1 - C_{long})x_i,$$

где x_i — непосредственное значение i -го семпла сигнала; C_{long} — константа затухания, вычисляемая по формуле

$$C_{long} = 1 - \frac{\Delta T}{T_{long}},$$

где ΔT — временной интервал, определяющий затухание сигнала; T_{long} — временной интервал, определяющий участок осреднения сигнала.

В алгоритме вычисляется первая дискретная производная сигнала $x(t)$, определяемая по формуле

$$\dot{x}_i = \frac{x_i - x_{i-1}}{\Delta t_{x_i}},$$

где x_0 инициализируется средним значением $x(t)$ в первом осредняющем интервале T_{long} ; Δt_{x_i} — разница во времени между временем семпла x_i и временем семпла x_{i-1} . Затем в алгоритме генерируется набор отфильтрованных сигналов $X_{n_i} = X_{n_i}^{(LP)}$, где LP означает фильтр низких частот. Для этого сперва формируются два сигнала, проходящие через фильтры высоких частот HP_1 и HP_2 :

$$\begin{aligned} X_{n_i}^{(HP_1)} &= C_n^{(HP)} \times [X_{n_{i-1}}^{(HP_1)} + \dot{x}_i - \dot{x}_{i-1}], \\ X_{n_i}^{(HP_2)} &= C_n^{(HP)} \times [X_{n_{i-1}}^{(HP_2)} + X_{n_i}^{(HP_1)} - X_{n_{i-1}}^{(HP_1)}], \end{aligned}$$

и после формируется характеристическая функция $CF = X_n^{(LP)}$, определяемая фильтром низких частот:

$$X_{n_i}^{(LP)} = X_{n_{i-1}}^{(LP)} + C_n^{(LP)} \times [X_{n_i}^{(HP_2)} - X_{n_{i-1}}^{(HP_2)}],$$

где константа фильтра $C_n^{(HP)} = w_n / (w_n + \Delta T)$ и константа $C_n^{(LP)} = \Delta T / (w_n + \Delta T)$. Временная константа $w_n = T_n / 2\pi$. Период $T_n = 2^n \Delta T$. Количество требуемых низкочастотных фильтров N_{band} выбирается так, чтобы период $T_{N_{band}-1} = 2^{N_{band}-1} \Delta T$ был больше, чем преобладающий период в сигнале, фаза которого должна быть пропикирована. Номера формируемых характеристических функций CF меняются как $n = 0, \dots, N_{band} - 1$ [10].

На рис. 5 показан пример работы алгоритма пикирования первых вступлений сигнала для некоторого синтетического сейсмического сигнала при искусственно выбранном числе низкочастотных фильтров $N_{band} = 2$ при значениях $\Delta T = 4.0$ мс (рис. 5, а) и $\Delta T = 20.0$ мс (рис. 5, б) с формированием характеристической функции CF для каждого из значений этих ΔT . Анализировать алгоритмом предполагается итоговую суммарную характеристическую функцию CF (рис. 5, в), на которой вступления выражены ярче всего в виде резкого пиковидного скачка ее значений.

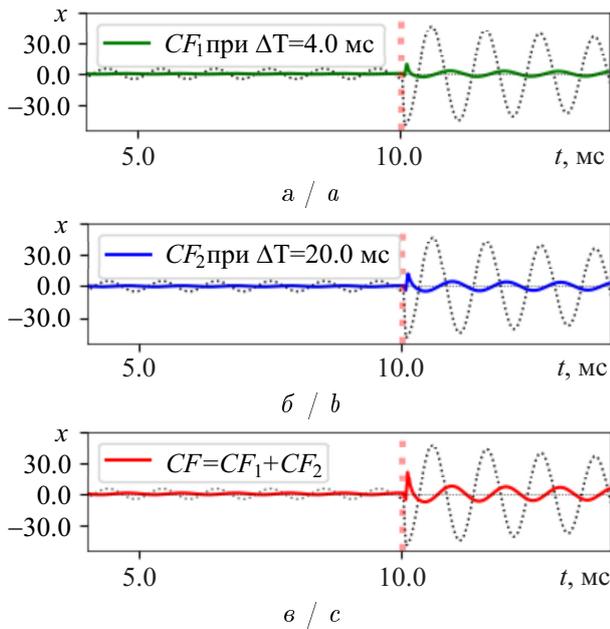


Рис. 5. Пример работы алгоритма с накопительным фильтром на искусственном сейсмическом сигнале, изображенном пунктиром. Первые вступления пришли в момент времени $t_0 = 10$ мс. Функции CF построены: a — для $\Delta T = 4.0$ мс; b — для $\Delta T = 20.0$ мс; c — суммарная CF

Fig. 5. An example of the Filter Picker algorithm work. The artificial seismic signal is pictured as the dotted line. The first breaks are registered at time $t_0 = 10$ ms. Characteristic functions CF are represented: a is for $\Delta T = 4.0$ ms; b is for $\Delta T = 20.0$ ms; c shows cumulative CF

корреляции Пирсона между двумя близко расположенными сейсмическими трассами. Две трассы, одна из которых находится чуть ближе к пункту возбуждения, а другая — чуть дальше, должны по своей форме повторять друг друга, но более дальняя трасса Y смещена по оси времени на количество отсчетов времени τ относительно трассы X . Коэффициент корреляции r лежит в пределах от -1 до $+1$, где $r = +1$ означает полную прямо пропорциональную зависимость между двумя величинами, $r = -1$ означает полную обратно пропорциональную зависимость, $r = 0$ означает отсутствие взаимозависимости [26]. Коэффициент парной корреляции $r(\tau)$ вычисляется по формуле [27]

$$r(\tau) = \frac{n \sum_{i=0}^{i=n} x_i y_{i+\tau} - \sum_{i=0}^{i=n} x_i \sum_{i=0}^{i=1} y_{i+\tau}}{\sqrt{n \sum_{i=0}^{i=n} x_i^2 - (\sum_{i=0}^{i=n} x_i)^2} \times \sqrt{n \sum_{i=0}^{i=n} y_{i+\tau}^2 - (\sum_{i=0}^{i=n} y_{i+\tau})^2}}, \quad (9)$$

где τ — количество семплов по оси времени, на которое сдвинута трасса Y относительно трассы X ; x_i — семплы трассы X ; y_i — семплы трассы Y ; n — количество семплов во временном окне, определяющем участок на двух трассах, в котором вычисляется коэффициент парной корреляции. Значение сдвига τ подбирается экспериментально так, чтобы обеспечить максимум коэффициента корреляции $r(\tau)$ [27]. При этом первое вступление на одной из имеющихся в (9) двух трасс, X и Y , должно быть заранее определено вручную или одним из методов, рассмотренных в пп. 1.1–1.5. Тогда, выбрав оптимальное смещение τ , можно узнать время вступления на другой близко расположенной трассе [28].

Для иллюстрации на рис. 5 представлены только две построенные низкочастотными фильтрами характеристические функции CF с итоговой суммарной CF . В работе [10] демонстрируются примеры с пятью разными построенными CF для разных ΔT , не считая суммарной CF .

1.6. Корреляционный подход

Рассмотренные в пп. 1.1–1.5 методы автоматического и полуавтоматического пикирования работают с каждой записью сигнала отдельно без учета взаимного расположения регистрируемых сейсмических трасс. Корреляционный подход может применяться совместно с одним или несколькими из предыдущих методов и призван учитывать взаимную пространственную зависимость регистрируемых времен первых вступлений полезного сейсмического сигнала для улучшения качества пикирования и повышения точности введения статических поправок [24]. Корреляция может быть выполнена неверно в случае зашумленных данных, поэтому необходимо выполнить их предварительную обработку для ослабления шумов [25].

В основе данного подхода лежит расчет линейного коэффициента парной



В случае нескольких трасс итоговые сдвиги τ_i^* , $i = 1, \dots, m$, где m — количество трасс, в работе Ю, Хэ, Хоу и Тана [29] предлагается усреднять методом наименьших квадратов. Для этого решается система уравнений

$$R\tau^* = \Delta\tau, \quad (10)$$

где R — матрица парных коэффициентов корреляции, состоящая из элементов $r_{i,j}$, i, j — номера трасс, между которыми рассчитывается коэффициент парной корреляции; $\Delta\tau$ — вектор ранее определенных неусредненных сдвигов трассами, состоящий из элементов $\Delta\tau_{i,j}$ [30]. Тогда искомым вектор решений τ^* может быть найден через выражение

$$\tau^* = (R^T R)^{-1} R^T \Delta\tau. \quad (11)$$

Поскольку в случае большого количества трасс решение (11) может быть вычислительно сложным, на практике применяется небольшое число соседних трасс [30]. Пример системы (10) для случая пяти трасс, где из матрицы парных корреляций R убраны симметричные элементы, приведен в выражении [30]

$$\begin{pmatrix} 1 & -1 & 0 & 0 & 0 \\ 1 & 0 & -1 & 0 & 0 \\ 1 & 0 & 0 & -1 & 0 \\ 1 & 0 & 0 & 0 & -1 \\ 0 & 1 & -1 & 0 & 0 \\ 0 & 1 & 0 & -1 & 0 \\ 0 & 1 & 0 & 0 & -1 \\ 0 & 0 & 1 & -1 & 0 \\ 0 & 0 & 1 & 0 & -1 \\ 0 & 0 & 0 & 1 & -1 \\ 1 & 1 & 1 & 1 & 1 \end{pmatrix} \begin{pmatrix} \tau_1^* \\ \tau_2^* \\ \tau_3^* \\ \tau_4^* \\ \tau_5^* \end{pmatrix} = \begin{pmatrix} \Delta\tau_{1,2} \\ \Delta\tau_{1,3} \\ \Delta\tau_{1,4} \\ \Delta\tau_{1,5} \\ \Delta\tau_{2,3} \\ \Delta\tau_{2,4} \\ \Delta\tau_{2,5} \\ \Delta\tau_{3,4} \\ \Delta\tau_{3,5} \\ \Delta\tau_{4,5} \\ 0 \end{pmatrix},$$

где, согласно работе Куммерова, исходные коэффициенты корреляции $r_{i,j}$ округлены до целых значений $+1$, 0 и -1 для учета только общей прямой зависимости, или обратной зависимости, или отсутствия зависимости регистрируемых фаз на ближайших трассах в соответствии с подобранными пороговыми значениями для $r_{i,j}$ [31]. Согласно Куммерову, такого округления достаточно на практике, и значение корреляции $r_{i,j} > 0.7$ говорит о похожести волновых форм трасс i и j [31].

1.7. Алгоритм динамического искривления времени (DTW)

В работе Сенина [32] применяется похожий на рассмотренный в п. 1.6 корреляционный подход, который именуется алгоритмом динамического искривления времени (DTW), но вместо матрицы парных корреляций в нем предлагается использовать рассчитанную стоимостную матрицу, оценивающую расстояние между двумя временными последовательностями, представленными сейсмическими трассами X и Y . Каждому семплу трассы X ставится в соответствие максимально похожий семпл из трассы Y [1]. Зная предварительно пропикированный вручную или автоматически семпл вступления на трассе X , можно найти соответствующий ему семпл на трассе Y . Матрица расстояний C , также именуемая локальной стоимостной матрицей, состоящая из элементов $c_{i,j}$, задается выражением

$$C = \|c_{i,j}\| = \|x_i - y_j\|,$$

где x_i — семплы трассы X , y_j — семплы трассы Y , $i = 0, \dots, N - 1$ и $j = 0, \dots, M - 1$, N — число семплов в трассе X , M — число семплов в трассе Y . После расчета матрицы C

выполняется расчет накопленной стоимостной матрицы D , элементы $d_{i,j}$ которой задаются согласно выражению [1]

$$D = \begin{cases} d_{0,j} = \sum_{j=0}^{M-1} c_{0,j} & \text{для первой строки,} \\ d_{i,0} = \sum_{i=0}^{N-1} c_{i,0} & \text{для первого столбца,} \\ d_{i,j} = \min(d_{i-1,j-1}, d_{i-1,j}, d_{i,j-1}) + c_{i,j} & \text{для остальных элементов.} \end{cases}$$

В случае, если трассы X и Y полностью идентичны, оптимальное смещение для всех их семплов между ними будет нулевым, т.е. минимальные значения элементов $d_{i,j}$ матрицы D будут располагаться строго по ее главной диагонали. В противном случае выполняется поиск минимальных значений $d_{i,j}$ матрицы D , несколько смещенных относительно диагонали. Пример такой матрицы, взятой из работы [1], приведен в выражении

$$D = \begin{matrix} 4.7 & \langle \widehat{1.9} \rangle & 5.5 & 11 & 17 & 21 & 21 & 27 \\ 11 & 5 & \langle \widehat{2.3} \rangle & 5.2 & 7.9 & 8 & 12 & 20 \\ 18 & 9.7 & 3.5 & \langle \widehat{3.6} \rangle & \langle \widehat{4.7} \rangle & 6.1 & 12 & 22 \\ 25 & 13 & 3.6 & 5.9 & 5.9 & \langle \widehat{4.9} \rangle & 9.3 & 18 \\ 29 & 14 & 6.3 & 8.7 & 11 & 7.4 & \langle \widehat{6.6} \rangle & 13 \\ 30 & 15 & 11 & 14 & 16 & 12 & \langle \widehat{7.1} \rangle & 11 \\ 30 & 18 & 18 & 20 & 22 & 18 & \langle \widehat{9.2} \rangle & 9.5 \\ 32 & 23 & 26 & 29 & 31 & 26 & 13 & \langle \widehat{9.6} \rangle \end{matrix},$$

где элементы $\langle \widehat{d_{i,j}} \rangle$ отобраны среди всех элементов $d_{i,j}$ матрицы D алгоритмом так, чтобы сумма этих смещенных от главной диагонали значений стремилась к минимуму и формируемая ими ломаная линия, проходящая через матрицу по этим элементам, была непрерывна. Номера строк матрицы представляют собой номера семплов i трассы X , номера столбцов — семплы j трассы Y . По пересечению номеров строк i и столбцов j можно узнать, какому семплу трассы X поставлен в соответствие семпл трассы Y . Таким образом, имея пропикированное первое вступление на трассе X , можно узнать таковое и на сопоставляемой ей трассе Y . При этом одному семплу трассы X могут соответствовать несколько семплов трассы Y , что может привести к неоднозначности определения вступления. Алгоритмом в таком случае выбирается среднерасположенный семпл из такого множества неоднозначности с округлением итогового выбора вверх до целого числа. Особенно сильно проблема сопоставления семпла первого вступления встает в случае сильно зашумленных данных [1].

1.8. Нечеткая кластеризация методом k -средних (FCM)

В работе [33] предлагается использовать нечеткую кластеризацию методом k -средних для определения моментов времени первых вступлений сейсмических сигналов. Такая кластеризация расширяет традиционную кластеризацию методом k -средних введением дополнительных параметров нечеткости, в результате чего каждый элемент, вместо того чтобы принадлежать строго заданному кластеру с определенным центром, может одновременно принадлежать множеству кластеров с разными центрами. Включение параметров нечеткости позволяет лучше справляться с неоднозначностями при кластеризации зашумленных данных [34].

В отличие от традиционной кластеризации методом k -средних, которая приписывает каждому элементу кластеризуемого множества X значение принадлежности $\mu_{i,j} = 1$, если i -й элемент принадлежит кластеру j , и значение $\mu_{i,j} = 0$ в противном случае, нечеткая



кластеризация каждому кластеризуемому элементу задает значение принадлежности, лежащее в пределах интервала от 0 до 1 [35]. Пусть K — заранее определенное количество кластеров, на которое требуется разделить исходное множество X , имеющее n элементов x_i , тогда можно задать следующие ограничивающие условия на значения принадлежности $\mu_{i,j}$ [35]:

$$\sum_{j=1}^K \mu_{i,j} = 1, \quad \forall i \in [1, 2, \dots, n], \quad (12)$$

$$\sum_{i=1}^n \mu_{i,j} > 0, \quad \forall j \in [1, 2, \dots, K]. \quad (13)$$

Выражение (12) означает, что сумма значений принадлежности $\mu_{i,j}$ элементов x_i в случае каждого кластера j равна 1. Кроме того, согласно (13) каждому кластеру принадлежит по крайней мере один из элементов x_i [35]. Здесь $\mu_{i,j} \in [0, 1]$.

Согласно авторам работы [33], для каждой исходной сейсмической трассы сперва определяется интервал определенной длины, в пределах которого затем уже выполняется поиск первых вступлений, с целью уменьшения размера входных данных для дальнейшей кластеризации. Определение такого интервала авторами выполняется в пределах плавающего вертикального окна, имеющего заданную длину. На основе измерения энергии трассы и поиска значительного ее резкого увеличения определяется предварительное время первого вступления, от которого вперед и назад по оси времени отстраивается интервал заданной общей длины l . После этого этапа применяется второе окно, но уже горизонтальное. Предполагается, что времена вступлений между двумя соседними трассами не могут отличаться слишком сильно, поэтому для устранения нежелательных отскоков времен вступлений авторами в горизонтальном окне применяется медианный фильтр, усредняющий первые вступления. После того, как предварительные времена первых вступлений вычислены, применяется метод роя частиц (*PSO*) [33].

Целевая функция J_α , определенная для случая разбиения множества X на K кластеров и подлежащая минимизации, задается выражением

$$J_\alpha = \sum_{j=1}^K \sum_{i=1}^n \mu_{i,j}^\alpha d_{j,i}^\beta,$$

где значение принадлежности $\mu_{i,j} \in [0, 1]$, α — гиперпараметр контроля того, насколько нечеткими будут получаемые кластеры. Большие значения α означают большую нечеткость. Расстояние между центром j -го кластера c_j и i -м элементом x_i определяется метрикой $d_{i,j} = \|x_i - c_j\|$. Обычно применяется евклидово расстояние, т. е. параметр $\beta = 2$.

Алгоритм *PSO* применяется для поиска начальных центров кластеров перед применением *FCM* из-за способности *PSO* к глобальной оптимизации [33], при этом он сходится быстро и может быть легко распараллелен [36]. Пусть есть M частиц со случайно заданными начальными скоростями и позициями, которые требуется оптимальным образом распределить [36]. Пусть $\hat{x}_i(t)$ — лучшее решение, которое было найдено для i -й частицы перед итерацией t , $x^*(t)$ — лучшее решение среди всех частиц до итерации t . Для поиска оптимального распределения каждая частица обновляет свою скорость $v_i(t)$ и положение $x_i(t)$ согласно соответственно уравнениям [33, 36]

$$v_i(t+1) = wv_i(t) + \delta_1 rand_1 \times (\hat{x}_i(t) - x_i(t)) + \delta_2 rand_2 \times (x^*(t) - x_i(t)), \quad (14)$$

$$x_i(t+1) = x_i(t) + v_i(t) \times \Delta t_{t+1,t}(t), \quad (15)$$

где t — номер текущей итерации, $rand_1$ и $rand_2$ — случайные числа из интервала $[0, 1]$, δ_1 и δ_2 — две положительные константы ускорения $[1/(\text{итерация } t)]$, нужные для корректировки положения частицы с учетом лучшего глобального и лучшего локального решений, $\Delta t_{t+1,t}(t) = ((t+1) - t) = 1$, вес w применяется для балансировки глобального поиска.

Целевая функция алгоритма *PSO* задается уравнением

$$f(x_i) = \frac{\theta}{\pi + J_{FCM}},$$

где θ — параметр целевой функции, $\theta \leq \pi$, и обычно принимается $\theta = 2$. Скорость частицы по алгоритму *PSO* итеративно обновляется по формуле (14), а положение частицы — по формуле (15) [33]. J_{FCM} — целевая функция алгоритма применяемой нечеткой кластеризации методом k -средних:

$$J_{FCM} = \sum_{i,j} \sum_{k=1}^K \mu_{i,j,k}^\alpha (d_k)_{i,j}^2,$$

где α — гиперпараметр контроля нечеткости, i — номер семпла на j -й трассе в ранее определенном окне, $(d_k)_{i,j} = \|x_{i,j} - c_k\|$ — расстояние между элементом $x_{i,j}$ и центром k -го кластера c_k , K — количество центров кластеризации, $\mu_{i,j,k}$ — значение принадлежности элемента $x_{i,j}$ к кластеру с номером k [33].

После первичного расчета оптимальных положений первых вступлений в определенном интервале применяется нечеткая кластеризация методом k -средних. Значение принадлежности $\mu_{i,j,k}$ итеративно обновляется в соответствии с выражением [33]

$$\mu_{i,j,k} = \frac{1}{\sum_{p=1}^P \left(\frac{(d_k)_{i,j}}{(d_p)_{i,j}}\right)^{2/(\alpha-1)}},$$

где $(d_p)_{i,j}$ — расстояние между элементом $x_{i,j}$ и положением p -й частицы из метода роя частиц, P — количество частиц.

Центр кластеризации c_k обновляется в соответствии с выражением [33]

$$c_k = \frac{\sum_{i,j} \mu_{i,j,k}^\alpha x_{i,j}}{\sum_{i,j} \mu_{i,j,k}^\alpha}.$$

Формируемый из значений принадлежности $\mu_{i,j,k}$ к K кластерам трехмерный тензор M имеет вид

$$\begin{pmatrix} [\mu_{1,1,1} \cdots \mu_{1,1,K}] & \cdots & [\mu_{1,N,1} \cdots \mu_{1,N,K}] \\ \vdots & \ddots & \vdots \\ [\mu_{l,1,1} \cdots \mu_{l,1,K}] & \cdots & [\mu_{l,N,1} \cdots \mu_{l,N,K}] \end{pmatrix},$$

где l — вертикальная длина окна, определяющая количество кластеризуемых семплов данных по одной трассе, N — количество трасс, задаваемое горизонтальным окном, K — количество кластеров.

После выполнения *FCM* завершается определение K центров кластеров. Всего в работе [33] решено разбить входные данные после ограничения их горизонтальным и вертикальным окнами на 10 кластеров. Один из этих кластеров соответствует найденным первым вступлениям сейсмических волн.

2. Алгоритмы, основанные на применении нейронных сетей

2.1. Полносвязные нейронные сети

Полносвязная нейронная сеть состоит из входного, одного или нескольких скрытых слоев и одного или нескольких выходных слоев, каждый из которых характеризуется своим набором весов [37]. В общем виде многоуровневая нейронная сеть, состоящая из множества узлов, представленных перцептронами, изображена на рис. 6.

Каждый перцептрон обучается согласно определенному правилу, изменяя веса модели в соответствии с определенной величиной ошибки, характеризуемой разницей между рассчитанным нейронной сетью значением и априорно заданным эталоном [38].

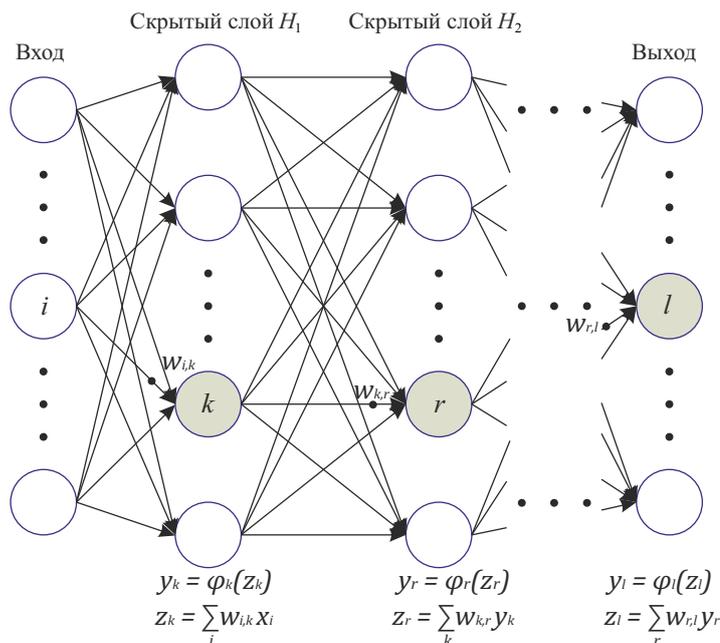


Рис. 6. Схема многоуровневой нейронной сети с несколькими скрытыми слоями. Три узла (перцептрона) k, r, l , принадлежащие разным слоям сети, закрашены цветом

Fig. 6. The multilayer neural network scheme with several hidden layers. Three colored nodes (perceptrons) k, r, l belong to different layers

На вход нейронной сети подается сигнал x , на выходе получается преобразованный сигнал y_p ; z_p — внутренние состояния сети, зависящие от выходных значений предыдущего слоя y_{p-1} и от весов $w_{p-1,p}$. При наличии достаточного количества промежуточных скрытых слоев в такой нейронной сети она становится способной улавливать и определять присутствие даже сложных нелинейных взаимосвязей входных сигналов с эталоном. Нахождение весов составной многоуровневой нейронной сети называется глубоким обучением [39]. Выход каждого слоя вычисляется по рассчитанным весам с помощью функции активации $\phi(z_i)$. Обычно применяются нелинейные функции активации, так как порой невозможно построить качественную линейную зависимость между входом и выходом. Если все слои нейронной сети имеют линейные функции активации, то вся цепочка промежуточных слоев может быть представлена в виде линейной зависимости выхода нейронной сети y_p от ее входа x [40, 41]. Ниже в общем виде представлены две известные и широко применяемые функции активации: сигмовидная (рис. 7, а)

$$\phi(z_i) = \frac{1}{(1 + e^{-z_i})^m},$$

где m — гиперпараметр, определяющий градиент функции $\phi(z_i)$; и ректифицированная (рис. 7, б) [40]

$$\phi(z_i) = \begin{cases} z_i & \text{при } z_i \geq 0, \\ \alpha_i z_i & \text{при } z_i < 0, \end{cases}$$

где α — малый по значению являющийся гиперпараметром коэффициент, принимаемый обычно ≈ 0.01 .

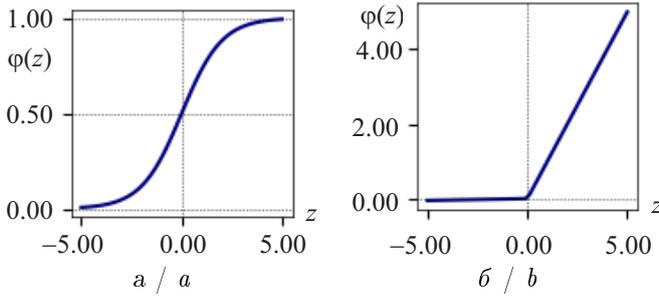


Рис. 7. Функции активации нейронных сетей: *a* — сигмовидная, $m = 1.0$; *b* — ректифицированная, $\alpha = 0.01$
 Fig. 7. The neural network activation functions: *a* is sigmoid, $m = 1.0$; *b* is rectified, $\alpha = 0.01$

Полносвязная нейронная сеть может быть применена и для определения первых вступлений на регистрируемых сейсмических сигналах. Выполнив обучение на отобранной подходящей обучающей выборке, сеть становится способной обобщить накопленную в ходе ее обучения информацию и на случаи, не включенные в состав обучающей выборки [42]. Обучающая выборка должна содержать качественные пропикированные первые вступления, отделяющие область

шумов от полезного сигнала, и каждой точке из этих областей присвоена своя метка: шум или полезный сигнал, для чего требуется контроль со стороны специалиста, который должен выбрать подходящий набор сейсмических данных и обеспечить правильность пикировок [43]. После обучения такой нейронной сети она может отделять полезный сигнал от шумов и на новых для нее данных.

Поскольку исходные данные могут иметь шумы, мешающие обучению и работе нейронной сети, имеет смысл выполнять предобработку входных сейсмических данных для подавления шумов [44]. Разумеется, не обязательно подавать на вход нейронной сети сигнал в его исходном виде непосредственно, он может быть преобразован в другой вид, для чего от входного сигнала рассчитывается некоторая характеристическая функция *CF*. Нейронные сети могут включать в себя рассмотренные ранее классические алгоритмы, что демонстрируется, например, в работе Джентили и Брагато, где с полносвязной нейронной сетью используется алгоритм *STA/LTA*, рассмотренный в п. 1.2 [44].

2.2. Нейронные сети Кохонена

Данный вид нейронных сетей широко применяется для решения задач кластеризации данных. Входной слой здесь имеет m входных наборов данных, а выходной слой — n наборов данных. Нейроны в выходном слое организованы в виде матрицы, и все выходные нейроны связаны друг с другом, в отличие от входных нейронов, которые не имеют никаких связей друг с другом, но все нейроны входного слоя имеют полную связь со всеми нейронами выходного слоя, и каждая такая связь имеет свой вес $w_{i,j}$ [45]. Связи между входным и выходным слоем являются возбуждающими, а внутренние связи выходного слоя — подавляющими. Количественная характеристика связи j -го возбуждающего вектора v_j с i -м нейроном выходного слоя может быть задана выражением [45]

$$I_i^{v_j} = w_i v_j = \sum_{k=1}^m w_{i,k} v_{k,j},$$

где $w_i = (w_{i,1}, w_{i,2}, \dots, w_{i,m})$ характеризует силу воздействия на i -й выходной нейрон от вектора воздействия v_j .

Нейроны выходного слоя соревнуются друг с другом — в результате обучения нейрон-победитель и его окружение объединяются [45]. Вектор весов нейрона-победителя лучше всего соответствует входному шаблону, для этого нейрона и его окружения происходит перерасчет их объединенных параметров [46]. Пусть $u_{i,j}$ — характеристика силы горизонтальной связи между i -м и k -м нейронами выходного слоя, находящимися в позициях r_i и r_k соответственно. Тогда количественная характеристика горизонтального воздей-



ствия на i -й нейрон выходного слоя среди горизонтального набора нейронов l записывается в виде [45]

$$I_i^{(l)} = \sum_{k \in N, k \neq i} u_{i,j} h(r_k - r_i) \phi_k,$$

где ϕ_k — выход функции активации k -го нейрона, h — вейвлет-функция «Мексиканская шляпа» [45]

$$h_{c,i}(t) = \alpha(t) \exp\left(-\frac{\|r_c - r_i\|^2}{2\sigma^2(t)}\right),$$

где t характеризует прошедшее время обучения модели, $\sigma(t)$ — среднее квадратичное отклонение гауссовой функции, характеризует радиус окружения нейрона-победителя, i — нейрон-сосед нейрона-победителя выходного слоя c , $\alpha(t)$ характеризует скорость обучения, $\|r_c - r_i\|$ — расстояние между позициями r_c и r_i нейронов c и i соответственно. В общем виде функция «Мексиканская шляпа» изображена на рис. 8, а схема нейронной сети Кохонена — на рис. 9.

Определение моментов времени первых вступлений на 3D данных сейсморазведки с использованием нейронной сети Кохонена описано в работе [47]. В ней авторы получают сперва приблизительную оценку положений первых вступлений, анализируя трассы в скользящих окнах, разделяя трассы на три части: зону микросейсм, зону первого срыва и зону максимальной амплитуды, следующую за первым срывом (рис. 10).

Затем, после получения приблизительных вступлений, авторы их фильтруют по критерию не превышения кажущейся скоростью сейсмических волн в тестируемой точке заданного порога [48]:

$$\left| V_2 - \frac{V_1 + V_3}{2} \right| > V_{thr},$$

где V_{thr} — заданный порог, V_2 — кажущаяся скорость в тестируемой точке, V_1 и V_3 — кажущиеся скорости в соседних точках. После фильтрации следует корректировка первых вступлений с помощью нейронной сети Кохонена [47]. На основе данного подхода создан программный комплекс автоматической пикировки «MPick» [49].

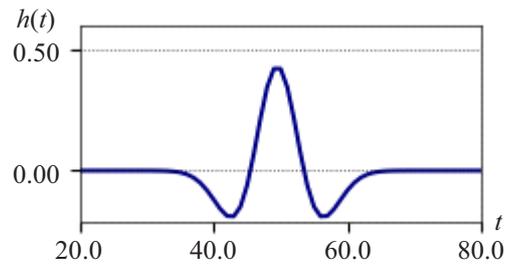


Рис. 8. Общий вид вейвлет-функции «Мексиканская шляпа» $h(t)$
Fig. 8. “Mexican Hat” wavelet function general view $h(t)$

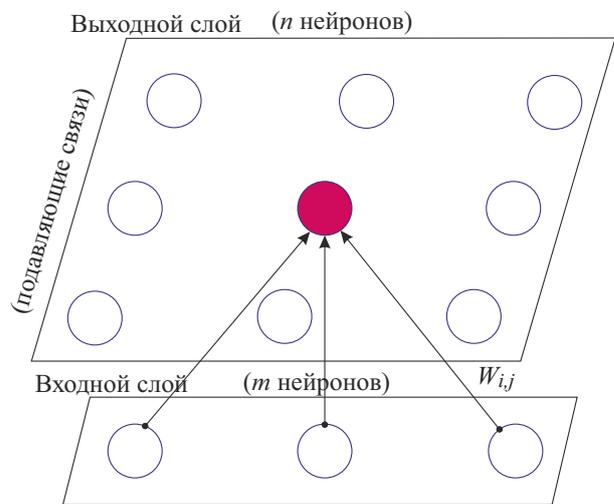


Рис. 9. Общий вид нейронных сетей Кохонена
Fig. 9. Kohonen neural network general view

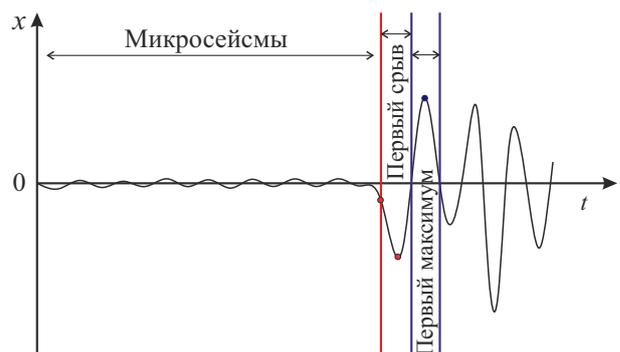


Рис. 10. Схематичное разделение сейсмической трассы на три участка: микросейсм, участок первого срыва и участок следующего за срывом максимума (цвет онлайн)

Fig. 10. The seismic trace schematic separation into three parts: The microseismic part, the first breaks part and the part of the maximum following the first break (color online)

2.3. Сверточные нейронные сети (CNN)

Нейронные сети, называемые сверточными, являются чрезвычайно популярным видом нейронных сетей, используемых в глубоком обучении. Данные сети широко используются в распознавании объектов на изображениях [50].

Глубокое обучение для автоматической пикировки вступлений — быстро развивающееся направление исследований в последнее время. В работе [51] проведен численный анализ шести конкретных реализаций нейронных сетей глубокого обучения для пикирования вступлений на сейсмических сигналах, и во всех них в том или ином виде их частью являются сверточные нейронные сети. Серьезным преимуществом CNN является то, что они предоставляют некоторую степень устойчивости своей работы к возможным сдвигам и искажениям во входных данных [52]. Маленькие простые CNN-основанные сети показывают большую устойчивость, чем другие простые нейронные сети [53], при этом они требуют меньше параметров для обучения [2].

Сверточные сети имеют в своем составе множество фильтров, применяющих операцию свертки к входным данным. В общем виде операция свертки задается выражением [54]

$$\mathbf{x}_j = \phi(\mathbf{o} * \mathbf{w}_j), \quad j = 1, 2, \dots, J,$$

где \mathbf{x}_j — j -й вектор выходных значений, \mathbf{o} — входной вектор, \mathbf{w}_j — применяемый фильтр, представляющий собой вектор весов, соединяющих вход \mathbf{o} с выходом \mathbf{x}_j , J — общее количество фильтров, $*$ — оператор свертки, ϕ — функция активации.

В общем виде сверточная нейронная сеть для определения первых вступлений, содержащая сверточный, выборочный и полносвязный слои, представлена на рис. 11 [54]. Эти слои лежат в основе сверточных нейронных сетей [2].

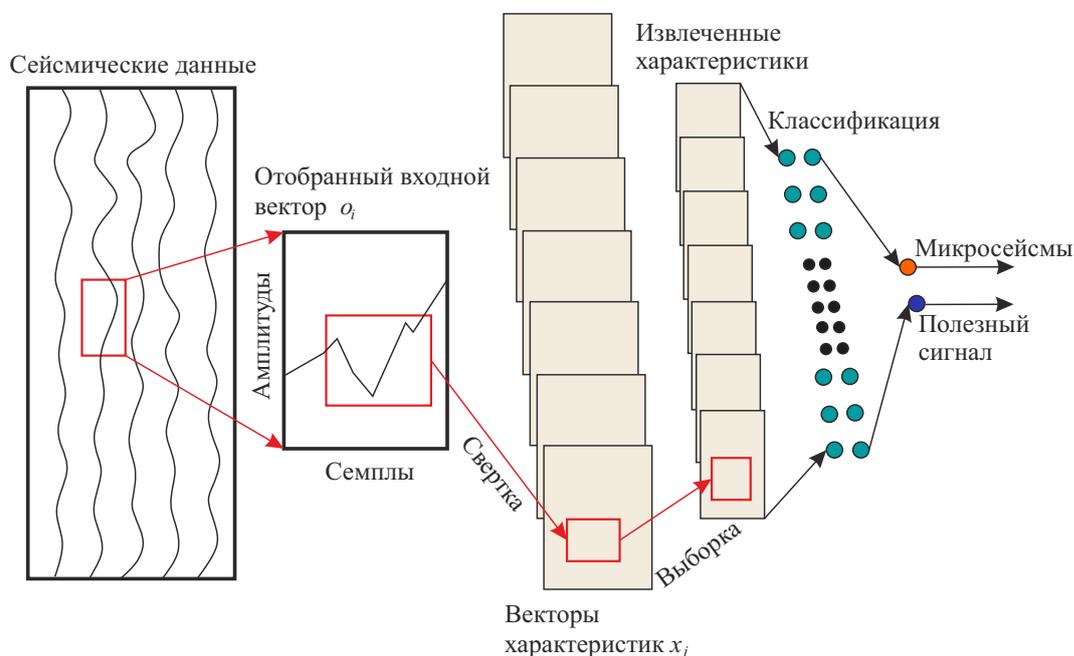


Рис. 11. Схема сверточной нейронной сети для классификации сейсмического сигнала по двум признакам: по области полезной части сигнала и по области микросейсмов
 Fig. 11. The scheme of a convolutional neural network for the seismic signal classification using two flags, marking whether a data sample belongs to microseismic noise or to the useful informational part



Сверточный слой является ключевым в *CNN*. Он имеет два задаваемых параметра — размер и глубину, веса же задаются случайно и оптимизируются автоматически. В общем виде сверточный слой задается формулой [2]

$$x_j^{(l)} = \phi(x_i^{(l-1)} * w_{i,j}^{(l)} + b_j^{(l)}),$$

где $x_i^{(l-1)}$ — выход i -го нейрона на слое $(l-1)$, $x_j^{(l)}$ — выход j -го нейрона слоя l , $w_{i,j}^{(l)}$ — сверточное ядро, $b_j^{(l)}$ — смещение.

Выборочный слой применяется для уменьшения размера нейронной сети с целью повышения вычислительной эффективности. Самые распространенные виды выборочного слоя: усредняющий слой, выбирающий среднее значение, и максимизирующий слой, выбирающий максимальное значение из локальных характеристик [2].

Полносвязный слой отвечает за распределение найденных ключевых характеристик, представляющих собой одномерный вектор, подаваемый на его вход. Этот вектор формируется после прохождения первых двух слоев — сверточного и выборочного. В полносвязном слое каждый нейрон на входе связан со всеми нейронами на выходе. Необходимое количество полносвязных слоев и нейронов в выходном слое выбирается исходя из решаемой задачи. Данный слой задается выражением [2]

$$x_j^{(l)} = \phi(w_{i,j}^{(l)} x_i^{(l-1)} + b_j^{(l)}),$$

где $x_i^{(l-1)}$ — выход i -го нейрона на слое $(l-1)$, $x_j^{(l)}$ — выход j -го нейрона слоя l после полносвязного слоя, $w_{i,j}^{(l)}$ — матрица весов, $b_j^{(l)}$ — смещение.

Для целей пикирования имеет смысл сперва примерно определить первые вступления, например, прокоррелировав их прямой линией, и задать определенной ширины интервал для дальнейшего уточнения вступлений. Обучающие входные данные необходимо промаркировать, присвоив -1 микросейсам и $+1$ области полезного сигнала [2]. После обучения *CNN* способна находить в новых подаваемых на вход дискретных сигналах похожие шаблоны из обучающей выборки и присваивать новым данным соответствующую метку, относя их к микросейсам или к полезной части сигнала.

Заключение

Рассмотренные подходы к автоматизации пикирования первых вступлений полезного сейсмического сигнала применяются в специальных программных комплексах, при этом каждая конкретная реализация таких программ имеет свой набор алгоритмов, состав которого определяется создателями программы. Для решения задачи определения вступлений могут быть применены как классические алгоритмы, не использующие нейронные сети, так и современные нейросетевые подходы, при этом последние могут включать в себя некоторую необходимую комбинацию классических алгоритмов. Одни подходы работают с каждым сигналом по отдельности, другие же учитывают пространственное взаиморасположение регистрируемых сейсмических трасс и основаны на предположении о том, что сигналы от одного и того же источника, зарегистрированные разными приемниками, должны быть схожими, с некоторым смещением по оси времени. В общем виде схема рассмотренных подходов к пикированию первых вступлений представлена на рис. 12.

Таблица с полученными значениями оценки точности пикировок авторами соответствующих исследований приведена ниже. Однако необходимо заметить, что прямо сравнивать между собой полученные оценки в таблице некорректно, поскольку исследования проведены на разных исходных данных.



Рис. 12. Схема рассмотренных подходов к автоматическому пикированию первых вступлений сейсмических волн (цвет онлайн)

Fig. 12. The scheme of the considered seismic first break picking approaches (color online)

Оценки точности подходов к пикированию первых вступлений

Table. First breaks picking approaches accuracy estimation

Подход	Источник	Тип данных	Метрика	Оценка
STA/LTA	[5]	Сейсмологические	Precision	В окне 0.473 с найдены 74% вступлений в широкополосных трассах и 87% вступлений на короткопериодных трассах, тест на специально отобранных трассах с заведомо ложными вступлениями дал 63% ложных срабатываний
FilterPicker	[5]	Сейсмологические	Precision	В окне 0.473 с найдены 90% вступлений в широкополосных и короткопериодных трассах, ложных срабатываний 20%, тест на специальных трассах с заведомо ложными вступлениями дал 20% ложных срабатываний
Статистика высокого порядка	[13]	Сейсмологические	Accuracy	В окне 1 с оценка 98.5%, ложных срабатываний 0.064%
Авторегрессионный подход	[16]	Сейсмологические	Ср. ошибка времени пикировки	0.55 с
Корреляционный подход	[27]	Сейморазведочные	Ошибка оценки скорости сейсмической волны	1.2%
Динамическое искривление времени (DTW)	-	Сейморазведочные	Нет данных	-



Окончание таблицы / Continuation of the Table

Подход	Источник	Тип данных	Метрика	Оценка
Нечеткая кластеризация (<i>FCM</i>)	[33]	Сейсмо-разведочные	<i>Accuracy</i>	При окне валидации 2 мс оценка 96.5% для данных с Синьцзянского нефтяного месторождения и 81.25% для данных с Сычуаньского нефтегазового бассейна
Полносвязные нейронные сети	[37]	Сейсмо-разведочные	Средне-квадратичное отклонение ошибок пикировок	8.1897 мс без доп. шума; 7.2740 мс с добавленным шумом при <i>SNR</i> (отношение сигнал / шум) = 4; 8.2929 мс при <i>SNR</i> = 8; 8.2757 мс при <i>SNR</i> = 13
Нейронные сети Кохонена	–	Сейсмо-разведочные	Нет данных	–
Сверточные нейронные сети (<i>CNN</i>)	[51]	Сейсмо-логические	Площадь под кривой (<i>AUC</i>)	Для нескольких протестированных моделей оценки следующие: BasicPhaseAE – 0.768; CRED – 0.952; DPP – 0.942; EQTransformer – 0.965; GPD-Orig – 0.928; GPD – 0.952; PhaseNet – 0.955

В таблице метрика *Precision* определяется как $Precision = TP / (TP + FP)$, а метрика *Accuracy* определяется как $Accuracy = (TP + TN) / (TP + TN + FP + FN)$, где *TP* – количество верноположительных, *TN* – количество верноотрицательных, *FP* – количество ложноположительных и *FN* – количество ложноотрицательных пикировок [55]. Если чувствительность *SE* определить как $SE = TP / (TP + FN)$, а специфичность *SP* – как $SP = TN / (FP + TN)$, то характеристическая функция *ROC* есть зависимость *SE* от $1 - SP$, тогда площадь под кривой $AUC = \int_0^1 ROC(t_{hr}) dt_{hr}$ [56], где t_{hr} – время регистрации очередного порога в сейсмической трассе, который может быть первым вступлением или ложным первым вступлением. $AUC = 1$ означает превосходный результат, а $AUC = 0.5$ означает неспособность модели анализировать данные и корректно определять вступления [51].

Данные в таблице приведены только для продольных волн.

Список литературы

1. Souza W. E., Cerqueira A. G., Porsani M. J. First-break prediction in 3-D land seismic data using the dynamic time warping algorithm // Geophysical Journal International. 2024. Vol. 237, iss. 1. P. 402–418. DOI: <https://doi.org/10.1093/gji/ggae048>
2. Yin Y., Han L., Zhang P., Lu Z., Shang X. First-break picking of large-offset seismic data based on CNNs with weighted data // Remote Sensing. 2023. Vol. 15, iss. 2. Art. 356. DOI: <https://doi.org/10.3390/rs15020356>
3. Trnkoczy A. Understanding and parameter setting of STA/LTA trigger algorithm // New Manual of Seismological Observatory Practice 2 (NMSOP-2) / ed. by P. Bormann. Potsdam : Deutsches GeoForschungsZentrum GFZ, 2012. P. 1–20. DOI: https://doi.org/10.2312/GFZ.NMSOP-2_IS_8.1
4. Sharma B. K., Kumar A., Murthy V. M. Evaluation of seismic events detection algorithms // Journal of the Geological Society of India. 2010. Vol. 75, iss. 3. P. 533–538. DOI: <https://doi.org/10.1007/s12594-010-0042-8>
5. Vassallo M., Satriano C., Lomax A. Automatic picker developments and optimization: A strategy for improving the performances of automatic phase pickers // Seismological Research Letters. 2012. Vol. 83, iss. 3. P. 541–554. DOI: <https://doi.org/10.1785/gssrl.83.3.541>
6. Küperkoch L., Meier T., Diehl T. Automated event and phase identification // New Manual of



- Seismological Observatory Practice 2 (NMSOP-2) / ed. by P. Bormann. Potsdam : Deutsches GeoForschungsZentrum GFZ, 2012. P. 1–52. DOI: https://doi.org/10.2312/GFZ.NMSOP-2_ch16
7. *Li X., Shang X., Wang Z., Dong L., Weng L.* Identifying *P*-phase arrivals with noise: An improved kurtosis method based on DWT and STA/LTA // *Journal of Applied Geophysics*. 2016. Vol. 133. P. 50–61. DOI: <https://doi.org/10.1016/j.jappgeo.2016.07.022>
 8. *Akram J., Eaton D. W.* A review and appraisal of arrival-time picking methods for downhole microseismic data // *Geophysics*. 2016. Vol. 81, iss. 2. DOI: <https://doi.org/10.1190/geo2014-0500.1>, EDN: WUPDSV
 9. *Shen T., Tuo X., Li H., Liu Y., Rong W.* A first arrival picking method of microseismic data based on single time window with window length independent // *Journal of Seismology*. 2018. Vol. 22, iss. 6. P. 1613–1627. DOI: <https://doi.org/10.1007/s10950-018-9789-y>
 10. *Lomax A., Satriano C., Vassallo M.* Automatic picker developments and optimization: FilterPicker-A robust, broadband picker for real-time seismic monitoring and earthquake early warning // *Seismological Research Letters*. 2012. Vol. 83, iss. 3. P. 531–540. DOI: <https://doi.org/10.1785/gssrl.83.3.531>
 11. *Vaezi Y., Van der Baan M.* Comparison of the STA/LTA and power spectral density methods for microseismic event detection // *Geophysical Journal International*. 2015. Vol. 203, iss. 3. P. 1896–1908. DOI: <https://doi.org/10.1093/gji/ggv419>
 12. *Souza W. E., Manenti R. R., Porsani M. J.* Automatic first-breaks picking using linear moveout correction and complex seismic traces // 15th International Congress of the Brazilian Geophysical Society. 2017. P. 1538–1543. DOI: <https://doi.org/10.1190/sbgf2017-300>
 13. *Nippress S. E., Rietbrock A., Heath A. E.* Optimized automatic pickers: Application to the ANCORP Data Set // *Geophysical Journal International*. 2010. Vol. 181, iss. 2. P. 911–925. DOI: <https://doi.org/10.1111/j.1365-246X.2010.04531.x>
 14. *Kuperkoch L., Meier T., Lee J., Friederich W.* Automated determination of *P*-phase arrival times at regional and local distances using higher order statistics // *Geophysical Journal International*. 2010. Vol. 181, iss. 2. P. 1159–1170. DOI: <https://doi.org/10.1111/j.1365-246X.2010.04570.x>
 15. *Liang Z., Wei J., Zhao J., Liu H., Li B., Shen J., Zheng C.* The statistical meaning of kurtosis and its new application to identification of persons based on seismic signals // *Sensors*. 2008. Vol. 8, iss. 8. P. 5106–5119. DOI: <https://doi.org/10.3390/s8085106>
 16. *Stampa J., Eckel F., Keers H., Lebedev S., Meier T.* Automated measurement of Teleseismic *P*-, *SH*- and *SV*-wave arrival times using autoregressive prediction and the instantaneous phase of multicomponent waveforms // *Geophysical Journal International*. 2024. Vol. 239, iss. 2. P. 936–949. DOI: <https://doi.org/10.1093/gji/ggae307>
 17. *Diehl T., Deichmann N., Kissling E., Husen S.* Automatic *S*-wave picker for local earthquake tomography // *Bulletin of the Seismological Society of America*. 2009. Vol. 99, iss. 3. P. 1906–1920. DOI: <https://doi.org/10.1785/0120080019>
 18. *Li H., Tuo X., Wang R., Courtois J.* A reliable strategy for improving automatic first-arrival picking of high-noise three-component microseismic data // *Seismological Research Letters*. 2019. Vol. 90, iss. 3. P. 1336–1345. DOI: <https://doi.org/10.1785/0220190038>
 19. *Irnaka T. M., Suryanto W., Wardhani P. W. K.* High accuracy automatic phase picking method in earthquake and microearthquake for earthquake early warning system (EEWS) and geothermal field in Indonesia // 3rd Jogja International Conference on Physics. 2012.
 20. *Ахметсафин Р. Д., Ахметсафина Р. З.* Статистические методы оценки времен первых вступлений по записям волнового акустического каротажа // *Каротажник*. 2014. Т. 18, вып. 4. С. 54–60. DOI: <https://doi.org/10.21455/gr2017.4-5>, EDN: SAXANF
 21. *Sedlak P., Hirose Y., Enoki M., Sikula J.* Arrival time detection in thin multilayer plates on the basis of Akaike information criterion // *Journal of Acoustic Emission*. 2008. Vol. 26. P. 182–188.
 22. *St-Onge A.* Akaike information criterion applied to detecting first arrival times on microseismic data // *SEG Technical Program Expanded Abstracts*. 2011. DOI: <https://doi.org/10.1190/1.3627522>
 23. *Zhou Z., Cheng R., Rui Y., Zhou J., Wang H.* An improved automatic picking method for arrival time of acoustic emission signals // *IEEE Access*. 2019. Vol. 7. P. 75568–75576. DOI: <https://doi.org/10.1109/ACCESS.2019.2921650>
 24. *Judson R. D., Sherwood J. W.* Static corrections for seismic traces by cross-correlation method. United States Patent Appl. No.: US00134099A; filed: 1971-04-05; application granted: 1973-05-01; published: 1973-05-01.
 25. *Campillo M., Roux P., Shapiro N. M.* Seismic, ambient noise correlation // *Encyclopedia of Solid*



- Earth Geophysics. Encyclopedia of Earth Sciences Series / ed. by H. K. Gupta. Dordrecht : Springer, 2011. P. 1230–1236. DOI: https://doi.org/10.1007/978-90-481-8702-7_218
26. *Asuero A. G., Sayago A., Gonzalez A. G.* The correlation coefficient: An overview // Critical Reviews in Analytical Chemistry. 2006. Vol. 36, iss. 1. P. 41–59. DOI: <https://doi.org/10.1080/10408340500526766>
 27. *Molyneux J. B., Schmitt D. R.* First-break timing; arrival onset times by direct correlation // Geophysics. 1999. Vol. 64, iss. 5. P. 1492–1501. DOI: <https://doi.org/10.1190/1.1444653>
 28. *Чернышов Г. С., Карпухин В. И.* Подход к автоматизации этапов обработки сейсморазведочных данных метода преломленных волн // Геофизические технологии. 2020. Вып. 1. С. 28–39. DOI: <https://doi.org/10.18303/2619-1563-2020-1-28>, EDN: ZOSFHO
 29. *Yu Z., He C., Hou G., Tan Y.* Arrival picking and refinement for microseismic events based on waveform cross-correlation // International Geophysical Conference. Beijing, China, 2018. P. 1354–1357. DOI: <https://doi.org/10.1190/IGC2018-332>
 30. *Tan Y., He C.* Improved methods for detection and arrival picking of microseismic events with low signal-to-noise ratios // Geophysics. 2016. Vol. 81, iss. 2. P. KS93–KS111. DOI: <https://doi.org/10.1190/geo2015-0213.1>
 31. *Kummerow J.* Joint arrival time optimization for microseismic events recorded by seismic borehole arrays // 75th EAGE Conference & Exhibition incorporating SPE EUROPEC. 2013. DOI: <https://doi.org/10.3997/2214-4609.20130401>
 32. *Senin P.* Dynamic time warping algorithm review // Information and Computer Science Department University of Hawaii at Manoa Honolulu. 2008. P. 1–23.
 33. *Gao L., Jiang Z., Min F.* First-arrival travel times picking through sliding windows and fuzzy C -means // Mathematics. 2019. Vol. 7, iss. 3. Art. 221. DOI: <https://doi.org/10.3390/math7030221>
 34. *Bao Y., Lu H., Gao Q.* Fuzzy K -means clustering without cluster centroids. arXiv:2404.04940v2 [cs.LG] 7 Nov 2024. 9 p. DOI: <https://doi.org/10.48550/arXiv.2404.04940>
 35. *Al-Augby S., Majewski S., Majewska A., Nermend K.* A comparison of K -means and fuzzy C -means clustering methods for a sample of Gulf Cooperation Council Stock Markets // Folia Oeconomica Stetinensia. 2014. Vol. 14, iss. 2. P. 19–36. DOI: <https://doi.org/10.1515/fofi-2015-0001>
 36. *Wang D., Tan D., Liu L.* Particle swarm optimization algorithm: An overview // Soft Computing. 2017. Vol. 22, iss. 2. P. 387–408. DOI: <https://doi.org/10.1007/s00500-016-2474-6>
 37. *Kahrizi A., Hashemi H.* Neuron curve as a tool for performance evaluation of MLP and RBF Architecture in first break picking of seismic data // Journal of Applied Geophysics. 2014. Vol. 108. P. 159–166. DOI: <https://doi.org/10.1016/j.jappgeo.2014.06.012>
 38. *Basheer I. A., Hajmeer M.* Artificial neural networks: Fundamentals, computing, design, and application // Journal of Microbiological Methods. 2000. Vol. 43, iss. 1. P. 3–31. DOI: [https://doi.org/10.1016/S0167-7012\(00\)00201-3](https://doi.org/10.1016/S0167-7012(00)00201-3)
 39. *LeCun Y., Bengio Y., Hinton G.* Deep learning // Nature. 2015. Vol. 521. P. 436–444. DOI: <https://doi.org/10.1038/nature14539>
 40. *Dubey S. R., Singh S. K., Chaudhuri B. B.* Activation functions in deep learning: A comprehensive survey and benchmark. arXiv:2109.14545v3 [cs.LG] 28 Jun 2022. 18 p. DOI: <https://doi.org/10.48550/arXiv.2109.14545>
 41. *Feng J., Lu S.* Performance analysis of various activation functions in artificial neural networks // Journal of Physics: Conference Series. 2019. Vol. 1237, iss. 2. Art. 022030. DOI: <https://doi.org/10.1088/1742-6596/1237/2/022030>
 42. *Лазаренко М. А., Герасименко О. А., Остапчук Н. Н.* Нейросетевая модель поля времен первых вступлений сейсмических волн в Украине // Геофизический журнал. 2016. Т. 38, вып. 1. С. 97–103. DOI: <https://doi.org/10.24028/gzh.0203-3100.v38i1.2016.107726>, EDN: ZMIZMH
 43. *Pcea Fischetti A., Andrade A.* Automatic first break picking in seismic traces by neural network // 6th International Congress of the Brazilian Geophysical Society. 1999. Art. cp-215-00370. DOI: <https://doi.org/10.3997/2214-4609-pdb.215.sbgf068>
 44. *Gentili S., Bragato P.* A neural-tree-based system for automatic location of earthquakes in Northeastern Italy // Journal of Seismology. 2006. Vol. 10, iss. 1. P. 73–89. DOI: <https://doi.org/10.1007/s10950-005-9001-z>
 45. *Shen Y.-J., Wang M.-S.* Apply neural schemes to deformation objects // ICGST-GVIP Journal. 2005. Vol. 5, iss. 4.
 46. *Kajan S., Sekaj I., Lajtman M.* Cluster analysis applications in Matlab using Kohonen network // Institute of Control and Industrial Informatics. 2011. URL: https://www2.humusoft.cz/www/papers/tcp11/060_kajan.pdf (дата обращения: 16.09.2025).



47. Приезжев И. И., Иванов П. Д., Гаврилов С. С., Мамаев Д. А., Калинин А. Ю., Стенина Ю. В. Автоматическая пикировка первых вступлений с использованием машинного обучения // *Геофизика*. 2022. Вып. 1. С. 90–96. DOI: <https://doi.org/10.34926/geo.2022.65.65.001>, EDN: TAUBKQ
48. Приезжев И. И., Мамаев Д. А., Стенина Ю. В., Иванов П. Д. Использование элементов машинного обучения для автоматической пикировки первых вступлений // *Геомодель 2021 : материалы 23-й конференции по вопросам геологоразведки и разработки месторождений нефти и газа*. Москва : ООО «ЕАГЕ Геомодель», 2021. Ст. 114. DOI: <https://doi.org/10.3997/2214-4609.202157135>, EDN: HNWDZL
49. Силкин А. М., Багрова И. А., Ревяко А. В. Мрпк и ИИ: новые возможности в автоматической пикировке первых вступлений // *Приборы и системы разведочной геофизики*. 2024. Вып. 3 (82). С. 7–11. EDN: SZGJMI
50. Wu H., Zhang B., Li F., Liu N. Semiautomatic first-arrival picking of microseismic events by using the pixel-wise convolutional image segmentation method // *Geophysics*. 2019. Vol. 84, iss. 3. DOI: <https://doi.org/10.1190/geo2018-0389.1>
51. Munchmeyer J., Woollam J., Rietbrock A., Tilmann F., Lange D., Bornstein T., Diehl T., Giunchi C., Haslinger F., Jozinovi D., Michelini A., Saul J., Soto H. Which picker fits my data? A quantitative evaluation of deep learning based seismic pickers // *Journal of Geophysical Research: Solid Earth*. 2022. Vol. 127, iss. 1. DOI: <https://doi.org/10.1029/2021JB023499>
52. Johnson S. W., Chambers D. J., Boltz M. S., Koper K. D. Application of a convolutional neural network for seismic phase picking of mining-induced seismicity // *Geophysical Journal International*. 2020. Vol. 224, iss. 1. P. 230–240. DOI: <https://doi.org/10.1093/gji/ggaa449>
53. St-Charles P.-L., Rousseau B., Ghosn J., Nantel J.-P., Bellefleur G., Schetselaar E. A multi-survey dataset and benchmark for first break picking in hard rock seismic exploration // *Fourth Workshop on Machine Learning and the Physical Sciences (NeurIPS 2021)*. 2021. URL: https://ml4physicalsciences.github.io/2021/files/NeurIPS_ML4PS_2021_3.pdf (дата обращения: 16.09.2025).
54. Chen Y., Zhang G., Bai M., Zu S., Guan Z., Zhang M. Automatic waveform classification and arrival picking based on convolutional neural network // *Earth and Space Science*. 2019. Vol. 6, iss. 7. P. 1244–1261. DOI: <https://doi.org/10.1029/2018EA000466>
55. Rahman M. S. Understanding accuracy metrics in machine learning models // *Daffodil International University*. 2024. DOI: <https://doi.org/10.13140/RG.2.2.16140.83841>
56. Cali C., Longobardi M. Some mathematical properties of the ROC curve and their applications // *Ricerche di Matematica*. 2015. Vol. 64, iss. 2. P. 391–402. DOI: <https://doi.org/10.1007/s11587-015-0246-8>

References

1. Souza W. E., Cerqueira A. G., Porsani M. J. First-break prediction in 3-D land seismic data using the dynamic time warping algorithm. *Geophysical Journal International*, 2024, vol. 237, iss. 1, pp. 402–418. DOI: <https://doi.org/10.1093/gji/ggae048>
2. Yin Y., Han L., Zhang P., Lu Z., Shang X. First-break picking of large-offset seismic data based on cnns with weighted data. *Remote Sensing*, 2023, vol. 15, iss. 2, art. 356. DOI: <https://doi.org/10.3390/rs15020356>
3. Trnkoczy A. Understanding and parameter setting of STA/LTA trigger algorithm. In: Bormann P. (ed.) *New Manual of Seismological Observatory Practice 2 (NMSOP-2)*. Potsdam, Deutsches GeoForschungsZentrum GFZ, 2012, pp. 1–20. DOI: https://doi.org/10.2312/GFZ.NMSOP-2_IS_8.1
4. Sharma B. K., Kumar A., Murthy V. M. Evaluation of seismic events detection algorithms. *Journal of the Geological Society of India*, 2010, vol. 75, iss. 3, pp. 533–538. DOI: <https://doi.org/10.1007/s12594-010-0042-8>
5. Vassallo M., Satriano C., Lomax A. Automatic picker developments and optimization: A Strategy for improving the performances of automatic phase pickers. *Seismological Research Letters*, 2012, vol. 83, iss. 3, pp. 541–554. DOI: <https://doi.org/10.1785/gssrl.83.3.541>
6. Kuperkoch L., Meier T., Diehl T. Automated event and phase identification. In: Bormann P. (ed.) *New Manual of Seismological Observatory Practice 2 (NMSOP-2)*. Potsdam, Deutsches GeoForschungsZentrum GFZ, 2012, pp. 1–52. DOI: https://doi.org/10.2312/GFZ.NMSOP-2_ch16
7. Li X., Shang X., Wang Z., Dong L., Weng L. Identifying P-phase arrivals with noise: An improved



- kurtosis method based on DWT and STA/LTA. *Journal of Applied Geophysics*, 2016, vol. 133, pp. 50–61. DOI: <https://doi.org/10.1016/j.jappgeo.2016.07.022>
8. Akram J., Eaton D. W. A review and appraisal of arrival-time picking methods for downhole microseismic data. *Geophysics*, 2016, vol. 81, iss. 2. DOI: <https://doi.org/10.1190/geo2014-0500.1>, EDN: WUPDSV
 9. Shen T., Tuo X., Li H., Liu Y., Rong W. A first arrival picking method of microseismic data based on single time window with window length independent. *Journal of Seismology*, 2018, vol. 22, iss. 6, pp. 1613–1627. DOI: <https://doi.org/10.1007/s10950-018-9789-y>
 10. Lomax A., Satriano C., Vassallo M. Automatic picker developments and optimization: FilterPicker-A robust, broadband picker for real-time seismic monitoring and earthquake early warning. *Seismological Research Letters*, 2012, vol. 83, iss. 3, pp. 531–540. DOI: <https://doi.org/10.1785/gssrl.83.3.531>
 11. Vaezi Y., Van der Baan M. Comparison of the STA/LTA and power spectral density methods for microseismic event detection. *Geophysical Journal International*, 2015, vol. 203, iss. 3, pp. 1896–1908. DOI: <https://doi.org/10.1093/gji/ggv419>
 12. Souza W. E., Manenti R. R., Porsani M. J. Automatic first-breaks picking using linear moveout correction and complex seismic traces. *15th International Congress of the Brazilian Geophysical Society*, 2017, pp. 1538–1543. DOI: <https://doi.org/10.1190/sbgf2017-300>
 13. Nippres S. E., Rietbrock A., Heath A. E. Optimized automatic pickers: Application to the ANCORP Data Set. *Geophysical Journal International*, 2010, vol. 181, iss. 2, pp. 911–925. DOI: <https://doi.org/10.1111/j.1365-246X.2010.04531.x>
 14. Kuperkoch L., Meier T., Lee J., Friederich W. Automated determination of *P*-phase arrival times at regional and local distances using higher order statistics. *Geophysical Journal International*, 2010, vol. 181, iss. 2, pp. 1159–1170. DOI: <https://doi.org/10.1111/j.1365-246X.2010.04570.x>
 15. Liang Z., Wei J., Zhao J., Liu H., Li B., Shen J., Zheng C. The statistical meaning of kurtosis and its new application to identification of persons based on seismic signals. *Sensors*, 2008, vol. 8, iss. 8, pp. 5106–5119. DOI: <https://doi.org/10.3390/s8085106>
 16. Stampa J., Eckel F., Keers H., Lebedev S., Meier T. Automated measurement of Teleseismic *P*-, *SH*- and *SV*-wave arrival times using autoregressive prediction and the instantaneous phase of multicomponent waveforms. *Geophysical Journal International*, 2024, vol. 239, iss. 2, pp. 936–949. DOI: <https://doi.org/10.1093/gji/ggae307>
 17. Diehl T., Deichmann N., Kissling E., Husen S. Automatic *S*-wave picker for local earthquake tomography. *Bulletin of the Seismological Society of America*, 2009, vol. 99, iss. 3, pp. 1906–1920. DOI: <https://doi.org/10.1785/0120080019>
 18. Li H., Tuo X., Wang R., Courtois J. A reliable strategy for improving automatic first-arrival picking of high-noise three-component microseismic data. *Seismological Research Letters*, 2019, vol. 90, iss. 3, pp. 1336–1345. DOI: <https://doi.org/10.1785/0220190038>
 19. Irnaka T. M., Suryanto W., Wardhani P. W. K. High accuracy automatic phase picking method in earthquake and microearthquake for earthquake early warning system (EWS) and geothermal field in Indonesia. *3rd Jogja International Conference on Physics*, 2012.
 20. Akhmetsafin R. D., Akhmetsafina R. Z. Statistical techniques for first-arrival time evaluation from wave sonic logs. *Karotazhnik [Logger]*, 2014, vol. 18, iss. 4, pp. 54–60 (in Russian). DOI: <https://doi.org/10.21455/gr2017.4-5>, EDN: SAXANF
 21. Sedlak P., Hirose Y., Enoki M., Sikula J. Arrival time detection in thin multilayer plates on the basis of Akaike information criterion. *Journal of Acoustic Emission*, 2008, vol. 26, pp. 182–188.
 22. St-Onge A. Akaike information criterion applied to detecting first arrival times on microseismic data. *SEG Technical Program Expanded Abstracts*, 2011. DOI: <http://doi.org/10.1190/1.3627522>
 23. Zhou Z., Cheng R., Rui Y., Zhou J., Wang H. An improved automatic picking method for arrival time of acoustic emission signals. *IEEE Access*, 2019, vol. 7, pp. 75568–75576. DOI: <https://doi.org/10.1109/ACCESS.2019.2921650>
 24. Judson R. D., Sherwood J. W. *Static corrections for seismic traces by cross-correlation method*. United States Patent Appl. No.: US00134099A, filed: 1971-04-05, application granted: 1973-05-01, published: 1973-05-01.
 25. Campillo M., Roux P., Shapiro N. M. Seismic, ambient noise correlation. In: Gupta H. K. (ed.) *Encyclopedia of Solid Earth Geophysics. Encyclopedia of Earth Sciences Series*. Dordrecht, Springer, 2011, pp. 1230–1236. DOI: https://doi.org/10.1007/978-90-481-8702-7_218



26. Asuero A. G., Sayago A., Gonzalez A. G. The correlation coefficient: An overview. *Critical Reviews in Analytical Chemistry*, 2006, vol. 36, iss. 1, pp. 41–59. DOI: <https://doi.org/10.1080/10408340500526766>
27. Molyneux J. B., Schmitt D. R. First-break timing; arrival onset times by direct correlation. *Geophysics*, 1999, vol. 64, iss. 5, pp. 1492–1501. DOI: <https://doi.org/10.1190/1.1444653>
28. Chernyshov G. S., Karpukhin V. I. The approach to automating the processing stages of refracted seismic data. *Russian Journal of Geophysical Technologies*, 2020, iss. 1, pp. 28–39 (in Russian). DOI: <https://doi.org/10.18303/2619-1563-2020-1-28>, EDN: ZOSFHO
29. Yu Z., He C., Hou G., Tan Y. Arrival picking and refinement for microseismic events based on waveform cross-correlation. *International Geophysical Conference*. Beijing, China, 2018, pp. 1354–1357. DOI: <https://doi.org/10.1190/IGC2018-332>
30. Tan Y., He C. Improved methods for detection and arrival picking of microseismic events with low signal-to-noise ratios. *Geophysics*, 2016, vol. 81, iss. 2, pp. KS93–KS111. DOI: <https://doi.org/10.1190/geo2015-0213.1>
31. Kummerow J. Joint arrival time optimization for microseismic events recorded by seismic borehole arrays. *75th EAGE Conference & Exhibition incorporating SPE EUROPEC*, 2013. DOI: <https://doi.org/10.3997/2214-4609.20130401>
32. Senin P. Dynamic time warping algorithm review. *Information and Computer Science Department University of Hawaii at Manoa Honolulu*, 2008, pp. 1–23.
33. Gao L., Jiang Z., Min F. First-arrival travel times picking through sliding windows and fuzzy C-means. *Mathematics*, 2019, vol. 7, iss. 3, art. 221. DOI: <https://doi.org/10.3390/math7030221>
34. Bao Y., Lu H., Gao Q. *Fuzzy K-means clustering without cluster centroids*. arXiv:2404.04940v2 [cs.LG] 7 Nov 2024, 9 p. DOI: <https://doi.org/10.48550/arXiv.2404.04940>
35. Al-Augby S., Majewski S., Majewska A., Nermend K. A comparison of K-means and fuzzy C-means clustering methods for a sample of Gulf Cooperation Council Stock Markets. *Folia Oeconomica Stetinensia*, 2014, vol. 14, iss. 2, pp. 19–36. DOI: <https://doi.org/10.1515/fofi-2015-0001>
36. Wang D., Tan D., Liu L. Particle swarm optimization algorithm: An overview. *Soft Computing*, 2017, vol. 22, iss. 2, pp. 387–408. DOI: <https://doi.org/10.1007/s00500-016-2474-6>
37. Kahrizi A., Hashemi H. Neuron curve as a tool for performance evaluation of MLP and RBF architecture in first break picking of seismic data. *Journal of Applied Geophysics*, 2014, vol. 108, pp. 159–166. DOI: <https://doi.org/10.1016/j.jappgeo.2014.06.012>
38. Basheer I. A., Hajmeer M. Artificial neural networks: Fundamentals, computing, design, and application. *Journal of Microbiological Methods*, 2000, vol. 43, iss. 1, pp. 3–31. DOI: [https://doi.org/10.1016/S0167-7012\(00\)00201-3](https://doi.org/10.1016/S0167-7012(00)00201-3)
39. LeCun Y., Bengio Y., Hinton G. Deep learning. *Nature*, 2015, vol. 521, pp. 436–444. DOI: <https://doi.org/10.1038/nature14539>
40. Dubey S. R., Singh S. K., Chaudhuri B. B. *Activation functions in deep learning: A comprehensive survey and benchmark*. arXiv:2109.14545v3 [cs.LG] 28 Jun, 2022, 18 p. DOI: <https://doi.org/10.48550/arXiv.2109.14545>
41. Feng J., Lu S. Performance analysis of various activation functions in artificial neural networks. *Journal of Physics: Conference Series*, 2019, vol. 1237, iss. 2, art. 022030. DOI: <https://doi.org/10.1088/1742-6596/1237/2/022030>
42. Lazarenko M. A., Gerasimenko O. A., Ostapchuk N. N. Neural network model field of the first arrival of seismic waves in Ukraine. *Geophysical Journal*, 2016, vol. 38, iss. 1, pp. 97–103 (in Russian). DOI: <https://doi.org/10.24028/gzh.0203-3100.v38i1.2016.107726>, EDN: ZMIZMH
43. Ilcea Fischetti A., Andrade A. Automatic first break picking in seismic traces by neural network. *6th International Congress of the Brazilian Geophysical Society*, 1999, art. cp-215-00370. DOI: <https://doi.org/10.3997/2214-4609-pdb.215.sbgf068>
44. Gentili S., Bragato P. A neural-tree-based system for automatic location of earthquakes in Northeastern Italy. *Journal of Seismology*, 2006, vol. 10, iss. 1, pp. 73–89. DOI: <https://doi.org/10.1007/s10950-005-9001-z>
45. Shen Y.-J., Wang M.-S. Apply neural schemes to deformation objects. *ICGST-GVIP Journal*, 2005, vol. 5, iss. 4.
46. Kajan S., Sekaj I., Lajtman M. Cluster analysis applications in Matlab using Kohonen network. *Institute of Control and Industrial Informatics*, 2011. Available at: https://www2.humusoft.cz/www/papers/tcp11/060_kajan.pdf (accessed September 16, 2025).



47. Priezzhev I. I., Ivanov P. D., Gavrilov S. S., Mamaev D. A., Kalinin A. Yu., Stenina Yu. V. Automatic picking of the first breaks using machine learning. *Journal of Geophysics*, 2022, iss. 1, pp. 90–96 (in Russian). DOI: <https://doi.org/10.34926/geo.2022.65.65.001>, EDN: TAUBKQ
48. Priezzhev I. I., Mamaev D. A., Stenina Yu. V., Ivanov P. D. Using the elements of machine learning to automatically pick first breaks. *Geomodel' 2021* [Geomodel 2021. Proceedings of the 23rd conference on geological exploration and development of oil and gas fields]. Moscow, LLC "EAGE Geomodel", 2021, art. 114 (in Russian). DOI: <https://doi.org/10.3997/2214-4609.202157135>, EDN: HNWDZL
49. Silkin A. M., Bagrova I. A., Revyako A. V. Mpick and AI: New possibilities in automatic first breaks picking. *Pribory i sistemy razvedochnoy geofiziki* [Instruments and Systems for Exploration Geophysics], 2024, iss. 3 (82), pp. 7–11 (in Russian). EDN: SZGJMI
50. Wu H., Zhang B., Li F., Liu N. Semiautomatic first-arrival picking of microseismic events by using the pixel-wise convolutional image segmentation method. *Geophysics*, 2019, vol. 84, iss. 3. DOI: <https://doi.org/10.1190/geo2018-0389.1>
51. Munchmeyer J., Woollam J., Rietbrock A., Tilmann F., Lange D., Bornstein T., Diehl T., Giunchi C., Haslinger F., Jozinovi D., Michelini A., Saul J., Soto H. Which picker fits my data? A quantitative evaluation of deep learning based seismic pickers. *Journal of Geophysical Research: Solid Earth*, 2022, vol. 127, iss. 1. DOI: <https://doi.org/10.1029/2021JB023499>
52. Johnson S. W., Chambers D. J., Boltz M. S., Koper K. D. Application of a convolutional neural network for seismic phase picking of mining-induced seismicity. *Geophysical Journal International*, 2020, vol. 224, iss. 1, pp. 230–240. DOI: <https://doi.org/10.1093/gji/ggaa449>
53. St-Charles P.-L., Rousseau B., Ghosn J., Nantel J.-P., Bellefleur G., Schetselaar E. A multi-survey dataset and benchmark for first break picking in hard rock seismic exploration. *Fourth Workshop on Machine Learning and the Physical Sciences (NeurIPS 2021)*, 2021. Available at: https://ml4physicalsciences.github.io/2021/files/NeurIPS_ML4PS_2021_3.pdf (accessed September 16, 2025).
54. Chen Y., Zhang G., Bai M., Zu S., Guan Z., Zhang M. Automatic waveform classification and arrival picking based on convolutional neural network. *Earth and Space Science*, 2019, vol. 6, iss. 7, pp. 1244–1261. DOI: <https://doi.org/10.1029/2018EA000466>
55. Rahman M. S. Understanding accuracy metrics in machine learning models. *Daffodil International University*, 2024. DOI: <https://doi.org/10.13140/RG.2.2.16140.83841>
56. Cali C., Longobardi M. Some mathematical properties of the ROC curve and their applications. *Ricerche di Matematica*, 2015, vol. 64, iss. 2, pp. 391–402. DOI: <https://doi.org/10.1007/s11587-015-0246-8>

Поступила в редакцию / Received 16.09.2025

Принята к публикации / Accepted 19.12.2025

Опубликована / Published 02.03.2026