

УДК 550.834

Бурцев Григорий Евгеньевич

аспирант, инженер 1 категории,
отдел сейсморазведочных работ,
Томский государственный университет
систем управления и радиоэлектроники,
634050, г. Томск, пр. Ленина, 40;
АО «ТомскНИПИнефть»,
634027, Россия, г. Томск, пр. Мира, д.72
e-mail: Grigory.E.Burtsev@outlook.com

Немирович-Данченко Михаил Михайлович

доктор физико-математических наук,
профессор,
кафедра комплексной информационной без-
опасности электронно-вычислительных систем,
Томский государственный университет систем
управления и радиоэлектроники
e-mail: nmm@fb.tusur.ru

ОПРЕДЕЛЕНИЕ ПЕРВЫХ ВСТУПЛЕНИЙ НА ИСХОДНЫХ 2D СЕЙСМИЧЕСКИХ ДАННЫХ ПРИ ПОМОЩИ ПОЛНОСВЯЗНОЙ НЕЙРОННОЙ СЕТИ

Аннотация:

В статье рассматривается вопрос автоматического определения моментов времени первых вступлений сейсмических волн на данных 2D сейсморазведки с применением специально построенной и обученной нейронной сети. Описываются в общих чертах существующие подходы к автоматическому пикированию первых вступлений с применением нейронных сетей и без них. Дается характеристика актуальности проведенного исследования, приводится краткая информация о подготовке исходных данных к дальнейшему их применению для обучения модели. Приведено описание разработанного алгоритма, применяющего машинное обучение и специально обученную нейронную сеть. В основе предлагаемого способа лежит расчет накопленной зарегистрированными сейсмическими сигналами энергии, анализируемой до момента прихода первых вступлений и после него. При этом принимается, что сам найденный момент первых вступлений разделяет сейсмический сигнал на две части: на шумовую компоненту, представленную микросейсмами, и на полезную часть сигнала. Оценена точность полученных результатов, при этом в качестве достоверных эталонов, имеющих абсолютную точность, принимаются вручную определенные первые вступления. В качестве исходных данных применялись полевые сейсмические данные с месторождений Западной Сибири. Приводится проверка качества работы алгоритма, примененного к исходным данным с трех месторождений. Исходные полевые данные не подвергались предварительной обработке от шумов, чтобы построенная модель научилась правильно учитывать их наличие и качественно определять моменты времени первых вступлений. Исследование, описываемое в статье, посвящено только 2D сейсмической съемке, трехмерные сейсмические кубы в данной статье не рассматриваются.

Ключевые слова: Первые вступления, автоматическое пикирование, микросейсмы, сейсмический шум, нейронные сети, машинное обучение, 2D сейсмические данные.

DOI: 10.25635/2313-1586.2025.02.096

Burtsev Grigory E.

Postgraduate Student, 1st category Engineer
of the Seismic Survey Department,
Tomsk State University of Control Systems
and Radioelectronics,
40 Lenin Ave., 634050 Tomsk;
TomskNIPIneft JSC;
72 Mira Ave., 634027 Tomsk
e-mail: Grigory.E.Burtsev@outlook.com

Nemirovich-Danchenko Mikhail M.

Doctor of Physico-Mathematical Sciences,
Professor of the Department of Integrated
Information Security of Electronic Computing
Systems (Cybersecurity),
Tomsk State University of Control Systems
and Radio Electronics
e-mail: nmm@fb.tusur.ru

2D PROFILE SEISMIC WAVES FIRST BREAKS AUTOMATIC PICKING USING MACHINE LEARNING AND FULLY CONNECTED NEURAL NET

Abstract

The article discusses a new method of automatic detection of the first breaks of seismic waves. The method used is: 2D seismic data as its input with applying the specially trained neural net mode. Existing modern approaches to the first breaks detection are described in short. Some of these approaches use neural nets and some do not. The characteristics of relevance of conducted research is provided, the process of initial field seismic data preparation for the training the model is explained. The researched algorithm of automatic first breaks picking, that uses machine learning and special trained neural net, is given in details. The calculation of accumulated seismic traces energy lies in the basis of the proposed first breaks detection method. In the research it is presumed that the time moment of seismic waves first breaks separates seismic signal into two pieces: the first one, which is noise microseismic part, and the second one that is seismic waves information part. The accuracy of received during the investigation results is estimated in the paper. The reference first breaks time moments were taken from manual picks. The seismic field data from three of Western Siberia oilfields were used as initial input data to train and test the neural net. Seismic input data were not preprocessed to reduce noise that exists in raw data. This noise was not removed from the input in order to help the neural net adapt its parameters to confidently pick first breaks of seismic waves from raw field data. The research that is described in this text is dedicated only to 2D seismic data, 3D field seismic cubes were not considered.

Key words: first breaks, automatic picking, microseism, seismic noise, neural net, machine learning, 2D seismic data.

Введение

В сейсморазведке методом общей глубинной точки с целью учета влияния неровностей рельефа и верхней низкоскоростной части разреза применяется ввод статических поправок, который выполняет сдвиг сейсмических трасс к некоторому общему заранее определенному уровню приведения. Чем точнее определены моменты времени первых вступлений сейсмических волн, тем выше качество введенных статических поправок [1]. Однако само пикирование первых вступлений в общем случае на реальных данных сейсморазведки является крайне непростой задачей. В случае пикирования первых вступлений вручную сложность процедуры определяется значительным количеством часов, которые специалист-обработчик полевых сейсмических данных должен на нее потратить, особенно если речь идет о 3D сейсмических данных [2]. В случае автоматизированного либо автоматического пикирования перед запрограммированным алгоритмом, выполняющим определение первых вступлений, возникает проблема, связанная с неоднозначностью отделения области микросейсм от области полезного сейсмического сигнала.

Существуют различные алгоритмы автоматического определения моментов времени первых вступлений сейсмических волн. В самом простом случае они основаны на расчете некоторой энергетической характеристики сейсмического сигнала, это так называемые пороговые алгоритмы [3], которые неплохо работают на низкозашумленных данных [4]. В общем виде схематично работа порогового алгоритма приведена на рис. 1.




Рис. 1. Схема работы порогового алгоритма. Первое вступление обнаруживается при достижении абсолютной амплитудой x сигнала заранее заданного порогового значения ($+5,0$ и $-5,0$) в момент времени $t_0 = 5$ мс

Разумеется, необязательно исследовать непосредственно сам зарегистрированный сигнал, вместо этого можно анализировать среднеквадратичное значение этого сигнала, рассчитанное в определенном временном окне [3].

Немного более сложная группа алгоритмов исследует рассчитанные характеристики сигнала сразу в двух временных окнах разной длины, а именно в коротком и длинном скользящих окнах, в которых непрерывно вычисляется значение, характеризующее энергию сейсмической трассы во временном окне. Простейший из этих алгоритмов, называемый *STA / LTA* алгоритмом оценки фрактальной размерности, был представлен Алленом еще в 1978 г. [5]. По данному алгоритму выполняется вычисление значений характеристической функции CF , задаваемой выражением (1) [6]:

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

где $\dot{x}_i$ – это производная сигнала x по времени; C_i – это константа взвешивания, которая находится по выражению (2):

$$C_i = \frac{\sum_{j=1-W_{TA}+1}^i |x_j|}{\sum_{j=1-W_{TA}+1}^i |\dot{x}_j|}, \quad (2)$$

где W_{TA} – длина заданного временного окна; $|\dot{x}_j|$ – абсолютная величина дискретной производной по времени, которая находится как $|\dot{x}_j| = |x_j - x_{j-1}|$. Тогда выражения характеристик сигнала в коротком (STA) и длинном (LTA) временных окнах могут быть найдены из выражений (3) и (4), соответственно [7]:

$$STA_i = \frac{1}{W_{STA}} \times \sum_{j=i-W_{STA}+1}^i CF_j, \quad (3)$$

$$LTA_i = \frac{1}{W_{LTA}} \times \sum_{j=i-W_{LTA}+1}^i CF_j; \quad (4)$$

где W_{STA} и W_{LTA} – длины короткого и длинного временных окон, соответственно. По внезапному росту отношения λ_i , определяемого выражением (5), можно судить об окончании области регистрируемых микросейсм и начале области полезного сигнала [7, 8]. Схематично длинные и короткие временные окна изображены на рис. 2.

$$\lambda_i = \frac{STA_i}{LTA_i}. \quad (5)$$




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

Существует также авторегрессионный алгоритм, в котором во временном окне W_{TA} оценивается значение сигнала в будущий момент времени при помощи авторегрессионной функции [9]. По внезапному росту ошибок предсказания ε_t можно заключить, что предсказанное значение сигнала лежит уже вне области микросейсм. Сигнал $x(t)$ выражается через авторегрессионную функцию AR (6):

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

где X_t – вектор семплов сигнала; b_m – коэффициенты авторегрессии, найденные при помощи метода наименьших квадратов. Порядок p авторегрессии в работе [9] принимается как $p = 4$. Вместо характеристической функции здесь исследуется ошибка предсказания ε_t , которая в области шумов-микросейсм, как ожидается, будет примерно совпадать с шумом. Рост данной ошибки предсказания при этом связывается с переходом в область полезного сигнала.

С развитием информационных технологий распространение получили подходы к автоматическому пикированию, использующие нейронные сети и машинное обучение. Для решения данной задачи могут применяться различные виды нейронных сетей. Это может быть полносвязная нейронная сеть, многоуровневый перцептрон, имеющий несколько промежуточных слоев, каждый из которых имеет свою функцию активации. В таких нейронных сетях каждый узел, именуемый также нейроном, текущего слоя математически связан с каждым нейроном предыдущего слоя. Данные функции активации обычно принимаются нелинейными, так как в противном случае все зависимости промежуточных слоев могут быть сведены к линейной зависимости между входом x модели и ее выходом y [10].

В работе [11] для пикирования первых вступлений применяется нейронная сеть Кохонена. В ней все узлы выходного слоя связаны друг с другом, а нейроны входного слоя не имеют друг с другом никаких связей, но каждый нейрон входного слоя связан с каждым нейроном выходного слоя [12]. Сперва авторы [11] предлагают определить приблизительное время первых вступлений сейсмических волн с помощью анализа сигналов в скользящих окнах, выполнить фильтрацию полученных результатов простым отбором по пороговым значениям кажущихся скоростей сейсмических волн [13] и лишь затем использовать нейронную сеть Кохонена.

Сверточные нейронные сети (CNN), широко используемые для анализа изображений, могут быть применены и для выделения полезной части регистрируемого сейсмического сигнала [14]. Данные нейронные сети имеют устойчивость к помехам во входных данных [15], являясь одновременно с этим довольно гибкими и приспособляемыми к различным подаваемым на вход данным [16].

В исследовании, описываемом в данной статье, применена специальная реализация полносвязной нейронной сети, выполняющей автоматическое определение первых вступлений на исходных 2D сейсмических данных. Нейронная сеть на вход принимает специальным образом рассчитанную в интервалах энергетическую характеристику сейсмических трасс, для чего эти трассы отображаются в их фазовое пространство. Определение первых вступлений при помощи построенной обученной модели выполняется автоматически, от специалиста, однако, требуется выполнять контроль полученных результатов. 3D исходные сейсмические данные в настоящей статье не рассматриваются.

1 Полносвязная нейронная сеть для автоматического пикирования первых вступлений сейсмических волн

1.1 Отображение сейсмического сигнала в фазовое пространство

Для начала условно примем, что сейсмический сигнал $x(t)$, регистрируемый приемником некоторой сейсмической трассы, в области микросейсм имеет следующий вид (7):

$$x(t) = C_0 \sin(\omega t), \text{ при } t < t_0, \quad (7)$$

где C_0 – константа, малая по значению, близкая к нулю; t – время; $\omega = 2\pi$; t_0 – момент времени регистрации первых вступлений. После регистрации первых вступлений примем, что сигнал (7) принимает вид (8), постепенно затухающий с ростом времени t :

$$x(t) = \frac{C_0 \sin(\omega t)}{ct}, \text{ при } t \geq t_0, \quad (8)$$

где C – константа.

Производная по времени сигнала (7) в таком случае примет вид (9):

$$\dot{x}(t) = C_0 \omega \cos(\omega t), \text{ при } t < t_0, \quad (9)$$

а при времени $t \geq t_0$ производная сигнала (8) по времени становится вида (10):

$$\dot{x}(t) = \frac{C_0(\omega t \cos(\omega t) - \sin(\omega t))}{ct^2}, \text{ при } t \geq t_0. \quad (10)$$

На рис. 3 представлен синтетический сейсмический сигнал $x(t)$ в координатах $(x; t)$, $(\dot{x}; t)$. Регистрация первых вступлений при этом происходит в момент времени t_0 , после которого амплитуды сигнала $x(t)$ резко возрастают. До достижения момента времени t_0 сигнал имеет незначительные амплитуды колебаний, соответствующие микросейсмическому шуму.

Если отобразить синтетический сигнал $x(t)$ в координатах $(x; \dot{x})$, получится фазовый портрет сигнала. Данный фазовый портрет приведен ниже на рис. 4. В момент t_0 сигнал резко отскакивает от своих колебаний в окрестности точки с координатами $(0; 0)$, приобретая значительную амплитуду, но затем, с ростом времени t , при $t \rightarrow \infty$, сигнал опять приближается к общему аттрактору системы, находящемуся в точке $(0; 0)$ [17].




Рис. 3. Слева направо: а) затухающий после $t_0 = 5$ мс синтетический сигнал $x(t)$; б) производная по времени от данного затухающего сигнала




Рис. 4. Фазовый портрет синтетического сигнала $x(t)$

В случае дискретного синтетического сигнала, представленного на рис. 5 а, выполним разбиение его на интервалы, строго по моментам времени, когда сигнал достигает своих экстремумов (рис. 5 б). Отдельно отметим область локального подынтервала, в пределах которой сигнал совершает одностороннее колебание, но не пересекает нулевое значение своей амплитуды (рис. 5 в). Данный локальный подынтервал понадобится далее для формирования тензора исходных данных, подаваемого на вход модели.




Рис. 5. Слева направо:
а) дискретный синтетический сейсмический сигнал; б) экстремумы сигнала;
в) локальный подынтервал, в пределах которого сигнал не пересекает своего нуля

Дискретный сигнал из рис. 5 можно отобразить на плоскости в виде фазового портрета, аналогично непрерывному синтетическому сигналу (см. рис. 6 а). Локальный подынтервал (рис. 6 б) при этом тот же самый, что и на рис. 5 в. Точка A_1 при этом является точкой локального аттрактора сигнала, который совершает один оборот по часовой стрелке вокруг нее, достигая точки A_2 . Точка A_2' совпадает с точкой A_1 на плоскости фазового портрета, но относится к другому, более позднему моменту времени.




Рис. 6. Фазовый портрет синтетической дискретной сейсмической трассы.

Слева направо: а) закрашенный интервал 4 соответствует таковому на рис. 5 б;

б) закрашенная область – это локальный подынтервал, который соответствует таковому из рис. 5 в

Далее отметим, что данный сигнал можно растянуть вдоль оси времени t . В этом случае получаем дискретную параметрическую кривую данного сигнала (рис. 7 а). В данном трехмерном случае становится видно, как соотносятся между собой в пространстве параметрической кривой точки A_2 и A_2' (рис. 7 б).




Рис. 7. Параметрическая кривая дискретной синтетической сейсмической трассы.

Слева направо: а) интервал 4 соответствует таковому на рис. 5 б;

б) локальный подынтервал соответствует локальному подынтервалу из рис. 5 в

Примем, что закрашенные синим цветом области, отмеченные на рис. 7, которые формирует сигнал $x(t)$, характеризуют энергию сигнала в данных интервалах, что будет применено в дальнейшем при формировании тензора входных данных. Каждую такую площадь $\sum area_{\Delta}$ в пределах интервала можно аналитически посчитать как сумму площадей треугольников $area_{\Delta}$, применяя формулу Герона (11):

$$area_{\Delta} = \sqrt{s(s-a)(s-b)(s-c)}, \quad (11)$$

где a , b , c – длины сторон треугольника; s – половина периметра треугольника в пространстве.

1.2 Формирование нейронной сети и тензора исходных данных

Тензором называется массив элементов произвольного уровня вложенности. Обычная матрица, в которой элементы расположены по ее столбцам и строкам, – это тензор второго порядка. Вектор элементов – тензор первого порядка. В формируемой нейронной сети для ее обучения и дальнейших расчетов применено формирование тензора данных *tens* третьего порядка, который в общем виде представлен выражением (12):

$$tens = \begin{pmatrix} \begin{bmatrix} t_{1,1} & l_{1,1} & x_{1,1} \\ x_{desc,1,1} & x_{max,1,1} & \dot{x}_{max,1,1} \\ a_{tot,1,1}^+ & a_{tot,1,1}^- & \dot{a}_{tot,1,1}^+ \end{bmatrix} & \dots & \begin{bmatrix} t_{1,n} & l_{1,n} & x_{1,n} \\ x_{desc,1,n} & x_{max,1,n} & \dot{x}_{max,1,n} \\ a_{tot,1,n}^+ & a_{tot,1,n}^- & \dot{a}_{tot,1,n}^+ \end{bmatrix} \\ \vdots & \ddots & \vdots \\ \begin{bmatrix} t_{m,1} & l_{m,1} & x_{m,1} \\ x_{desc,m,1} & x_{max,m,1} & \dot{x}_{max,m,1} \\ a_{tot,m,1}^+ & a_{tot,m,1}^- & \dot{a}_{tot,m,1}^+ \end{bmatrix} & \dots & \begin{bmatrix} t_{m,n} & l_{m,n} & x_{m,n} \\ x_{desc,m,n} & x_{max,m,n} & \dot{x}_{max,m,n} \\ a_{tot,m,n}^+ & a_{tot,m,n}^- & \dot{a}_{tot,m,n}^+ \end{bmatrix} \end{pmatrix}, \quad (12)$$

где $i = \overline{1, m}$, m – количество семплов в трассе; $j = \overline{1, n}$, n – общее количество анализируемых сейсмических трасс, имеющих на профиле; $t_{i,j}$ – двойное время пробега; $l_{i,j}$ – оффсет; $x_{i,j}$ – зарегистрированные амплитуды, искусственно введенная переменная $x_{desc,i,j} = 1$, если $\dot{x}_{i,j} \leq 0$, и $x_{desc,i,j} = 0$, если $\dot{x}_{i,j} > 0$, $\dot{x}_{i,j}$ – дискретная производная сигнала по времени; $x_{max,i,j}$ – максимальное по модулю значение амплитуды на участке трассы между двумя экстремумами дискретного сигнала $x_{i,j}$. Величины $a_{tot,m,1}^+$, $a_{tot,m,1}^-$ и $\dot{a}_{tot,m,1}^+$ – это рассчитанные значения максимальных накопленных на интервалах энергий сейсмических трасс, которые в данной нейронной сети характеризуются площадью закрученной ленты, вычисляемой как сумма площадей треугольников при помощи формулы Герона (11) в фазовом пространстве. Так, $a_{tot,m,1}^+$ – максимальная накопленная в пределах интервала энергия трассы в системе координат $(x; \dot{x}; t)$ (см. рис. 7 а); $\dot{a}_{tot,m,1}^+$ – то же самое, но в координатах $(\dot{x}; \ddot{x}; t)$; $a_{tot,m,1}^-$ – максимальная накопленная энергия на локальном подынтервале в системе координат $(x; \dot{x}; t)$ (см. рис. 7 б), при этом величина $a_{tot,m,1}^- = 0$, если на текущем интервале нет локального аттрактора системы, формирующего локальный подынтервал.

Величины $x_{i,j}$ и $\dot{x}_{i,j}$ в формируемом тензоре предварительно нормированы на несмещенную оценку среднеквадратичного отклонения исходных амплитуд сигнала $x_{i,j}^*$ и производных сигнала $\dot{x}_{i,j}^*$, в которых зарегистрированные данные сейсмических трасс принадлежат одному пункту возбуждения. Обучение модели выполнено на основе данных с 1600 сейсмических трасс Колотушного месторождения. Вступления, принятые за эталоны и применяемые в качестве образцов при обучении модели, были пропикированы вручную.

Итоговая архитектура нейронной сети приведена на рис. 8. В модели имеются три промежуточных скрытых плотных слоя (*Плотный 1*, *Плотный 2*, *Плотный 3*), в которых применяется ректифицированная функция активации. Каждый нейрон текущего слоя связан с каждым нейроном предыдущего. *Выходной плотный* слой выполняет преобразование полученных значений в вероятности $p_i \in [0; 1]$, $i = \overline{1, m}$, m – количество дискретных семплов данных. Данные вероятности определяют принадлежность

регистрируемого сигнала к микросейсам либо к полезной сейсмической информации после первых вступлений. *Выходной бинарный* слой по заданному пороговому значению преобразует вероятности p_i к бинарной величине p_i' , при этом $p_i' = 0$ означает микросеймы, а $p_i' = 1$ означает область полезной сейсмической информации. На рис. 8 (*None, None, 9*) означает размерность тензора на входе слоя и на его выходе. При этом *None* означает произвольный размер. *Обрезочный* слой оставляет лишь первые 1501 семплов данных, применяемых далее для поиска вступлений. Здесь предполагается, что первые вступления не могут находиться в поздних временах t , поэтому оставшая часть трассы предварительно отбрасывается из анализа для того, чтобы облегчить вычисления. По умолчанию трассы группируются в наборы по 256 штук, подаваемые на вход модели, однако размер таких наборов является гиперпараметром, который можно менять.




Рис. 8. Архитектура нейронной сети для пикирования первых вступлений.
 В модели имеются следующие слои: входной, обрезочный, плотный 1, плотный 2, плотный 3, выходной плотный, выходной бинарный

2 Апробация построенной модели

Из данных с профиля Колотушного месторождения первые 1280 трасс использовались для обучения нейронной сети, по оставшимся 320 трассам осуществлялся контроль качества работы модели. Всего применены данные с 1600 сейсмических трасс. Построение модели и ее обучение выполнено в библиотеке *TensorFlow*; каждый проход обучения модели именуется эпохой. Процедуру обучения решено остановить на 50-й эпохе из-за выполаживания графика функции точности (*Accuracy*) (рис. 9 а) (13), это означает, что дальнейшее обучение на текущем наборе данных не имеет смысла.

$$Accuracy = \frac{TP+TN}{TP+FP+TN+FN}, \quad (13)$$

где TP , TN , FP , FN – это количество правильно определенных семплов полезной части сигнала, количество правильно определенных семплов микросеймов, количество не-

правильно определенных семплов полезной части сигнала и количество неправильно определенных семплов микросейсм, соответственно [18].




Рис. 9. Слева направо:

- а) график точности работы модели по данным Колотушного месторождения;
- б) проверка работы модели по данным Колотушного, Западно-Полуденного и Поньжевого месторождений

Дополнительно проведена проверка работы модели была на данных с Западно-Полуденного и Поньжевого месторождений. Гистограмма с подписанными значениями точности приведена на рис. 9 б. Демонстрация работы полученной модели приведена на рис. 10 а. Красными точками на сейсмограмме отмечены полученные значения времен первых вступлений. Модель уверенно находит вступления, которые расположены в окрестности горизонтальной линии t_0 (рис 10 б).




Рис. 10. Слева направо:

- а) пример работы модели на сейсмограмме с Колотушного месторождения, где красным цветом отмечены найденные моделью первые вступления;
- б) изображение области, в пределах которой модель находит первые вступления. Они располагаются в окрестности горизонтальной линии t_0 , от $t_0.min$ до $t_0.max$

Заключение

Результаты точности работы полученной нейронной сети (см. рис. 9 б) позволяют заключить, что построенная нейросетевая модель для автоматического пикирования первых вступлений способна качественно выполнять свою работу, во всяком случае на протестированных полевых данных с месторождений Западной Сибири. При этом само обучение модели выполнялось только лишь по данным Колотушного месторождения, но, уловив закономерности изменения амплитуд сейсмического сигнала, модель стала способной определять, относится ли каждый проверяемый семпл данных к микросейсмическому шуму либо к полезной части сигнала и на данных с месторождений, не участвовавших в обучении модели.

В проведенном исследовании вместо усложнения архитектуры самой нейронной сети упор сделан на предварительном расчете энергетических характеристик сейсмических трасс с отображением дискретных сигналов в фазовое пространство. Полученные первые вступления программой, написанной на языке *Python*, записываются в *segu* файл, в байты с 233 по 236, предназначенные специально для записи произвольной дополнительной информации, согласно стандарту *SEG Y rev 1*.

Исследование на текущий момент посвящено только 2D сейсмическим профилям, решение для 3D полевых сейсмических данных потребует модификации примененного алгоритма.

Список литературы

1. Souza W.E., Cerqueira A.G., Porsani M.J., 2024. First-break prediction in 3-D land seismic data using the dynamic time warping algorithm. *Geophysical Journal International*, 237: pp. 402–418. DOI: 10.1093/gji/ggae048.
2. Yin Y., Han L., Zhang P., 2023. First-Break Picking of Large-Offset Seismic Data Based on CNNs with Weighted Data. *Remote Sensing*, 15(2), 356. DOI: 10.3390/rs15020356.
3. Trnkoczy A., 2012. Understanding and parameter setting of STA/LTA trigger algorithm. *Potsdam, Germany: New Manual of Seismological Observatory Practice 2 (NMSOP-2)*. DOI: doi.org/0.2312/GFZ.NMSOP-2_IS_8.1.
4. Sharma B.K., Amod Kumar, Murthy V.M., 2010. Evaluation of Seismic Events Detection Algorithms. *Geological Society of India*, Vol.75, pp. 533-538. DOI: 10.1007/s12594-010-0042-8.
5. Vassallo M., Satriano C., Lomax F., 2012. Automatic Picker Developments and Optimization: A Strategy for Improving the Performances of Automatic Phase Pickers. *Seismological Research Letters*. DOI: 10.1785/gssrl.83.3.541.
6. Küperkoch L., Meier T., Diehl T., 2011. Automated Event and Phase Identification. *Potsdam, Germany: New Manual of Seismological Observatory Practice 2 (NMSOP-2)*. DOI: 10.2312/GFZ.NMSOP-2_ch16.
7. Li X., Shang X., Wang Z., Dong L., Weng L., 2016. Identifying P-phase arrivals with noise: An improved kurtosis method based on DWT and STA/LTA. *Journal of Applied Geophysics*. DOI: 10.1016/j.jappgeo.2016.07.022.
8. Shen T., Tuo X., Li H., Liu Y., Rong W., 2018. A first arrival picking method of microseismic data based on single time window with window length independent. *Springer Nature*. DOI: 10.1007/s10950-018-9789-y.
9. Stampa J., Eckel F., Keers H., Lebedev S., Meier T., AlpArray and SWATH-D Working Groups, 2024. Automated measurement of teleseismic P -, SH - and SV-wave arrival times using autoregressive prediction and the instantaneous phase of multicomponent waveforms. *Geophysical Journal International*. DOI: 10.1093/gji/ggae307.
10. Feng J., Lu Sh., 2019. Performance Analysis of Various Activation Functions in Artificial Neural Networks. *Journal of Physics: Conf. Series 1237 (2019) 022030*. DOI: 10.1088/1742-6596/1237/2/022030.

11. Приезжев И.И., Иванов П.Д., Гаврилов С.С., Мамаев Д.А., Калинин А.Ю., Стенина Ю.В., 2022. Автоматическая пикировка первых вступлений с использованием машинного обучения. *Геофизика*, № 1, С. 90-96. DOI: 10.34926/geo.2022.65.65.001.
12. Shen Yu-Ju, Wang Ming-Shi, 2005. Apply neural schemes to deformation objects. *Taiwan: ICGST-GVIP Journal*, Vol. 5, Issue 4.
13. Приезжев И.И., Мамаев Д.А., Стенина Ю.В., 2021. Использование элементов машинного обучения для автоматической пикировки первых вступлений. *Геомодель 2021, 23-я конференция по вопросам геологоразведки и разработки месторождений нефти и газа*. Москва: Издательство ООО «ЕАГЕ Геомодель», С.114.
14. Münchmeyer J., Woollam J., Rietbrock A., Tilmann F., Lange D., Bornstein T., Diehl T., Giunchi C., Haslinger F., Jozinovi'c D., Michelini A., Saul J., Soto H., 2021. Which picker fits my data? A quantitative evaluation of deep learning based seismic pickers. *arXiv:2110.13671v1 [physics.geo-ph]*. DOI: 10.48550/arXiv.2110.13671.
15. Johnson Sean W., Chambers Derrick J. A., Boltz Michael S., Koper Keith D., 2021. Application of a convolutional neural network for seismic phase picking of mining-induced seismicity. *Geophysical Journal International*, Volume 224, Issue 1. DOI: 10.1093/gji/ggaa449
16. St-Charles Pierre-Luc, Rousseau B., Ghosn J., Nantel Jean-Philippe, Bellefleur G., Schetselaar E., 2021. 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)*.
17. Krakovská H., Kuehn C., Longo I.P., 2024. Resilience of Dynamical Systems. *European Journal of Applied Mathematics*, 35: 155–200. DOI: 10.1017/S0956792523000141.
18. Terven J., Cordova-Esparza Diana M., Ramirez-Pedraza A., Chavez-Urbiola Edgar A., Romero-Gonzalez Julio A., 2023. Loss Functions and Metrics in Deep Learning. *arXiv:2307.02694*. DOI: 10.48550/arXiv.2307.02694.

References

1. Souza W.E., Cerqueira A.G., Porsani M.J., 2024. First-break prediction in 3-D land seismic data using the dynamic time warping algorithm. *Geophysical Journal International*, 237: pp. 402–418. DOI: 10.1093/gji/ggae048.
2. Yin Y., Han L., Zhang P., 2023. First-Break Picking of Large-Offset Seismic Data Based on CNNs with Weighted Data. *Remote Sensing*, 15(2), 356. DOI: 10.3390/rs15020356.
3. Trnkoczy A., 2012. Understanding and parameter setting of STA/LTA trigger algorithm. *Potsdam, Germany: New Manual of Seismological Observatory Practice 2 (NMSOP-2)*. DOI: doi.org/0.2312/GFZ.NMSOP-2_IS_8.1.
4. Sharma B.K., Amod Kumar, Murthy V.M., 2010. Evaluation of Seismic Events Detection Algorithms. *Geological Society of India*, Vol.75, pp. 533-538. DOI: 10.1007/s12594-010-0042-8.
5. Vassallo M., Satriano C., Lomax F., 2012. Automatic Picker Developments and Optimization: A Strategy for Improving the Performances of Automatic Phase Pickers. *Seismological Research Letters*. DOI: 10.1785/gssrl.83.3.541.
6. Küperkoch L., Meier T., Diehl T., 2011. Automated Event and Phase Identification. *Potsdam, Germany: New Manual of Seismological Observatory Practice 2 (NMSOP-2)*. DOI: 10.2312/GFZ.NMSOP-2_ch16.
7. Li X., Shang X., Wang Z., Dong L., Weng L., 2016. Identifying P-phase arrivals with noise: An improved kurtosis method based on DWT and STA/LTA. *Journal of Applied Geophysics*. DOI: 10.1016/j.jappgeo.2016.07.022.
8. Shen T., Tuo X., Li H., Liu Y., Rong W., 2018. A first arrival picking method of microseismic data based on single time window with window length independent. *Springer Nature*. DOI: 10.1007/s10950-018-9789-y.

9. Stampa J., Eckel F., Keers H., Lebedev S., Meier T., AlpArray and SWATH-D Working Groups, 2024. Automated measurement of teleseismic P -, SH - and SV-wave arrival times using autoregressive prediction and the instantaneous phase of multicomponent waveforms. *Geophysical Journal International*. DOI: 10.1093/gji/ggae307.
10. Feng J., Lu Sh., 2019. Performance Analysis of Various Activation Functions in Artificial Neural Networks. *Journal of Physics: Conf. Series 1237 (2019) 022030*. DOI: 10.1088/1742-6596/1237/2/022030.
11. Priezzhev I.I., Ivanov P.D., Gavrilov S.S., Mamaev D.A., Kalinin A.Yu., Stenina Yu.V., 2022. Avtomaticheskaya pikirovka pervykh vstuplenii s ispol'zovaniem mashinnogo obucheniya [Automatic picking of the first introductions using machine learning]. *Geofizika*, № 1, P. 90-96. DOI: 10.34926/geo.2022.65.65.001.
12. Shen Yu-Ju, Wang Ming-Shi, 2005. Apply neural schemes to deformation objects. *Taiwan: ICGST-GVIP Journal*, Vol. 5, Issue 4.
13. Priezzhev I.I., Mamaev D.A., Stenina Yu.V., 2021. Ispol'zovanie elementov mashinnogo obucheniya dlya avtomaticheskoi pikirovki pervykh vstuplenii [Use of machine learning elements to automatically pick the first intros]. *Geomodel' 2021, 23-ya konferentsiya po voprosam geologorazvedki i razrabotki mestorozhdenii nefi i gaza*. Moscow: Izdatel'stvo OOO "EAGE Geomodel", P.114.
14. Münchmeyer J., Woollam J., Rietbrock A., Tilmann F., Lange D., Bornstein T., Diehl T., Giunchi C., Haslinger F., Jozinovi'c D., Michelini A., Saul J., Soto H., 2021. Which picker fits my data? A quantitative evaluation of deep learning based seismic pickers. *arXiv:2110.13671v1 [physics.geo-ph]*. DOI: 10.48550/arXiv.2110.13671.
15. Johnson Sean W., Chambers Derrick J. A., Boltz Michael S., Koper Keith D., 2021. Application of a convolutional neural network for seismic phase picking of mining-induced seismicity. *Geophysical Journal International, Volume 224, Issue 1*. DOI: 10.1093/gji/ggaa449
16. St-Charles Pierre-Luc, Rousseau B., Ghosn J., Nantel Jean-Philippe, Bellefleur G., Schetselaar E., 2021. 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)*.
17. Krakovská H., Kuehn C., Longo I.P., 2024. Resilience of Dynamical Systems. *European Journal of Applied Mathematics*, 35: 155–200. DOI: 10.1017/S0956792523000141.
18. Terven J., Cordova-Esparza Diana M., Ramirez-Pedraza A., Chavez-Urbiola Edgar A., Romero-Gonzalez Julio A., 2023. Loss Functions and Metrics in Deep Learning. *arXiv:2307.02694*. DOI: 10.48550/arXiv.2307.02694.