

МОДЕЛЬ ГЛУБОКОГО ОБУЧЕНИЯ НА ОСНОВЕ ВЕЙВЛЕТ-РАЗЛОЖЕНИЯ ДЛЯ ВЫДЕЛЕНИЯ ВРЕМЕН ПРИХОДА СЕЙСМИЧЕСКИХ ФАЗ НА ЗАПИСЯХ ГРУППЫ ВЫСОКОЧАСТОТНЫХ СКВАЖИННЫХ ПРИЕМНИКОВ

Р. Д. Костолина*

Институт динамики геосфер имени академика М. А. Садовского Российской академии наук, Москва, Россия
**E-mail: kostolina.rd@phystech.edu*

Цель. Разработать и адаптировать модель глубокого обучения с использованием вейвлет-разложения для автоматического определения времени прихода P- и S-волн в данных высокочастотного мониторинга скважин. Эффективность модели оценивалась на основе наборов данных, полученных в ходе крупномасштабного полевого эксперимента HFTS2 (Hydraulic Fracturing Test Site 2). Эта задача имеет несколько важных особенностей, которые усложняют ее решение. Эксперимент включает множество станций, полученные данные нужно обрабатывать вместе. При этом количество станций в разных группах разное и не фиксированное, поэтому алгоритм не должен зависеть от их числа. Расположение станций тоже может сильно различаться. Данные записываются с высокой частотой и содержатся в огромном количестве файлов, поэтому традиционные методы обработки не справляются.

Модель. Модель была реализована с использованием библиотеки Pytorch. Для формирования пространства признаков использовалось логарифмическое вейвлет-преобразование исходного сигнала. Блок вейвлет-разложения (WS) формирует частотно-временное представление сигнала на основе вейвлет-декомпозиции. В качестве реализации WS была использована библиотека Kymatio. В результате применения WS каждый вектор формы сигнала из пакета записей сигналов преобразуется в двумерную матрицу характеристик. После этого применяется двумерный сверточный слой с единичным размером ядра, который линейно преобразует 3-канальное изображение каждой записи в 1-канальное изображение. Далее записи отправляются во второй модуль transformer-encoder, который реализует механизм взаимного внимания к записям группы станций. Конкретная реализация механизма самовнимания, используемого в этой работе, основана на скалярном произведении векторов записей, поэтому этот модуль, по сути, применяет маску их взаимных корреляций к векторам данных. Это позволяет осуществлять обмен информацией между всеми записями всех станций. Данные, полученные на выходе второго модуля transformer-encoder, преобразуются в линейные записи (слой «Flatten»), передаются на полносвязный слой, а затем в логистическую функцию (сигмоиду), которая сопоставляет данные на выходе полносвязного слоя с диапазоном (0, 1).

Обучение и валидация. Мы обучили модель, используя первую группу станций, пронумерованных от 1 до 14, из обучающего набора. Эта группа является самой большой, что делает ее наиболее подходящей для начального обучения. Для этой группы использовались только файлы без пропущенных значений. Всего для обучения был использован 12761 файл. На этапе валидации было использовано 3163 файла.

Результаты. Была разработана модель глубокого обучения для обнаружения P- и S-волн на записях с группы регистрирующих станций во время микросейсмического мониторинга. Модель была обучена на основе наборов данных, полученных в ходе крупномасштабного полевого эксперимента HFTS2. Новизна предлагаемого метода заключается в использовании модели вейвлет-разложения для выделения признаков и трансформерной архитектуры. Данная архитектура хотя и не является достаточно точной, но имеет универсальность и применима к различным конфигурациям приемников, даже отличающимся от обучающих наборов, при увеличении же точности на данной архитектуре она теряет свою универсальность. Эта модель отлично справляется с основными трудностями. Ее архитектура не зависит от количества станций в группе, что позволяет работать с любыми данными, даже с теми, на которых она не обучалась. Трансформерная архитектура позволяет одновременно учитывать информацию со всех станций группы.

A WAVELET DECOMPOSITION-BASED DEEP LEARNING MODEL FOR SEISMIC PHASE ARRIVAL TIME EXTRACTION FROM HIGH-FREQUENCY BOREHOLE RECEIVER

R. D. Kostolina*

Sadovsky Institute of Geospheres Dynamics of the Russian Academy of Sciences, Moscow, Russia

*E-mail: kostolina.rd@phystech.edu

Objective. To develop and adapt a deep learning model using wavelet decomposition for automatic P- and S-wave arrival time determination in high-frequency well monitoring data. Model performance was evaluated using datasets obtained during the large-scale HFTS2 (Hydraulic Fracturing Test Site 2) field experiment. The experiment involves multiple stations that must be processed together. The number of stations in different groups varies and is not fixed, so the algorithm should not depend on their number. The station locations can also vary significantly. The data is recorded at a high frequency and is contained in a huge number of files, making traditional processing methods insufficient

Model. The model was implemented using the Pytorch library. A logarithmic wavelet transform of the original signal is used to generate the feature space. The wavelet decomposition (WS) block generates a time-frequency representation of the signal based on the wavelet decomposition. The Kymatio library was used to implement the self-attention mechanism. The WS transforms each waveform vector from a batch of signal records into a two-dimensional feature matrix. A two-dimensional convolutional layer with a unit kernel is then applied, linearly transforming the three-channel image of each record into a single-channel image. The records are then sent to the second transformer-encoder module, which implements a mutual attention mechanism for recordings from a group of stations. The specific implementation of the self-attention mechanism used in this work is based on the dot product of the record vectors, so this module essentially applies a mask of their cross-correlations to the data vectors. This enables information exchange between all records from all stations. The data obtained at the output of the second transformer-encoder module is transformed into linear records (the «Flatten» layer), passed to a fully connected layer, and then to a logistic function (sigmoid), which maps the data at the output of the fully connected layer to the range (0, 1).

Training and Validation. We trained the model using the first group of stations, numbered 1 through 14, from the training set. This group is the largest, making it most suitable for initial training. Only files without missing values were used for this group.

Results. A deep learning model was developed for detecting P- and S-waves in records from a group of recording stations during microseismic monitoring. The model was trained using datasets obtained during the large-scale field experiment HFTS2 (Hydraulic Fracture Testing Site 2). The novelty of the proposed method lies in its use of a wavelet decomposition model for feature extraction and a transformer architecture. Although not highly accurate, this architecture is versatile and applicable to various receiver configurations, even those different from the training sets. However, as accuracy increases with this architecture, its versatility decreases. This model copes well with the main challenges. Its architecture is independent of the number of stations in the group, allowing it to work with any data, even data it wasn't trained on.