



ДЕТЕКЦИЯ ЗАПИСЕЙ СЛАБЫХ ЛОКАЛЬНЫХ ЗЕМЛЕТРЯСЕНИЙ С ИСПОЛЬЗОВАНИЕМ НЕЙРОННЫХ СЕТЕЙ

Н.А. Ульянов¹, С.В. Яскевич², П.А. Дергач^{1,3}, А.В. Яблоков^{1,3}

¹Новосибирский государственный университет, 630090, г. Новосибирск, ул. Пирогова, 1, Россия,

²Институт земной коры СО РАН, 664033, г. Иркутск, ул. Лермонтова, 128, Россия,

³Институт нефтегазовой геологии и геофизики им. А.А. Трофимука СО РАН,

630090, Новосибирск, просп. Акад. Коптюга, 3, Россия,

e-mail: YaskevichSV@ipgg.sbras.ru

Ручная обработка больших объемов данных непрерывных наблюдений локальных сейсмических сетей занимает много времени, поэтому для решения данной задачи применяются автоматические алгоритмы детекции сейсмических событий. Детерминистические методы решения задачи детекции, которые отлично справляются с определением сильных землетрясений, при определении слабых сейсмических событий (землетрясений) сталкиваются с критическими проблемами. В их основе лежат принципы, основанные на вычислении энергии, что вызывает множественные ошибки в детекции: слабые сейсмические события могут быть не определены, а высокоамплитудный шум может быть принят за событие. В нашей работе мы предлагаем метод детектирования, способный превосходить детерминистические методы в детекции событий на сейсмограммах, успешно определяя аналогичное или большее количество событий с меньшим числом ложных детекций.

Триггерование, триггер файл, магнитуда, детекция, детектирующая функция, землетрясение, сеть станций, сейсмическое событие, нейросеть, машинное обучение, разметка, сверточный слой

DETECTION OF RECORDS OF WEAK LOCAL EARTHQUAKES USING NEURAL NETWORKS

N.A. Ulyanov¹, S.V. Yaskevich², P.A. Dergach^{1,3}, A.V. Yablokov^{1,3}

¹Novosibirsk State University, Pirogov Str., 1, Novosibirsk, 630090, Russia,

²Institute of the Earth's Crust SB RAS, Lermontova Str., 128, Irkutsk, 664033, Russia,

³Trofimuk Institute of Petroleum Geology and Geophysics SB RAS, Koptuyug Ave., 3, Novosibirsk, 630090, Russia,

e-mail: YaskevichSV@ipgg.sbras.ru

Manual processing of large volumes of continuous observations produced by local seismic networks takes a lot of time, therefore, to solve this problem, automatic algorithms for detecting seismic events are used. Deterministic methods for solving the problem of detection, which do an excellent job of detecting intensive earthquakes, face critical problems when detecting weak seismic events (earthquakes). They are based on principles based on the calculation of energy, which causes multiple errors in detection: weak seismic events may not be detected, and high-amplitude noise may be mistakenly detected as an event. In our work, we propose a detection method capable of surpassing deterministic methods in detecting events on seismograms, successfully detecting a similar or more events with fewer false detections.

Triggering, trigger file, magnitude, detection, detection function, earthquake, network of stations, seismic event, neural network, machine learning, markup, convolutional layer

ВВЕДЕНИЕ

Землетрясения несут важную информацию о строении Земли, позволяя уточнять границы тектонических плит, предсказывать глобальные землетрясения и многое другое, поэтому регистрация и интерпретация сигналов от землетрясений очень важна для сейсмологии [Пузырев, 1997]. Глобальные сейсмические сети сфокусированы в большей мере на изучении землетрясений с большой магнитудой. Локальные сети сейсмических станций располагают в определенных областях, чтобы изучать местную сейсмичность. Такие сети используются для мониторинга активности вулканов, в областях активных горных работ с целью предсказания катастрофических событий [Еманов и др., 2009], для инженерных и разведочных целей [Землетрясения..., 2007]. Обработка данных глобальных сетей осуществляется в основном в автоматическом режиме в условиях качественно оборудованных станций и высокого соотношения сигнал/шум. С детектированием землетрясений хорошо справляются детерминистические методы, также применяются алгоритмы, основанные на использовании нейросетей [Akram et al., 2017].

Слабые землетрясения для глобальных сетей редко являются объектом интереса, т. к. станции расположены на большом удалении друг от друга, и волны от таких землетрясений наблюдаются на очень ограниченном числе сейсмостанций. Локальные сети чаще сфокусированы на слабых землетрясениях, для которых характерно низкое соотношение сигнал/шум. Применение подходов, хорошо зарекомендовавших себя в условиях высокого соотношения сигнал/шум, приводит к большому количеству ложных детекций. Чтобы уменьшить количество ложных детектирований, ведется работа над новыми алгоритмами. По результатам [Akram et al., 2017] было выявлено, что сверточные нейронные сети с несколькими слоями могут точно детектировать слабые землетрясения, однако применялась нейронная сеть к детекции синтетических микросейсмических событий по записям из скважины, уровень шума на которых был относительно низким. В нашей работе шум зачастую достигает уровня сигнала, т. к. обрабатываются данные поверхностной сейсмологии, и мы разрабатываем алгоритм, основанный на применении сверточных нейронных сетей, продолжая работы [Дергач, Логинов, 2019; Логинов и др., 2019]. В этой работе мы предлагаем описание своего подхода и сравниваем его результаты с известным в предметной области методом MER (описание приведено в работе [Coppens et al., 1985]).

ОПИСАНИЕ ИСПОЛЬЗУЕМОЙ НЕЙРОННОЙ СЕТИ

Ядром алгоритма детекции является сверточная нейронная сеть (СНС). Описание используемой архитектуры СНС приводится в табл. 1. Входной слой СНС – запись трехкомпонентного сейсмического сигнала (трассы). Выходной слой – два канала значений детектирующей функции в диапазоне (0.1), которые являются зеркальным отражением (обращением) друг друга относительно значения 0.5.

Таблица 1

Используемая архитектура сверточной нейронной сети

№ слоя СНС	Выполняемые процедуры	Размер
1	Вход (запись трехкомпонентного сейсмического сигнала)	$N \times 3$
2	Сверточный слой (Conv), функция активации – линейная (Linear), пакетная нормализация, обнуление 10 % значений весов.	$64 \times (N \times 16)$

3	Сверточный слой (Conv), функция активации – гиперболический тангенс (Tanh), пакетная нормализация, обнуление 10 % значений весов.	32x(Nx32)
4	Сверточный слой (Conv), функция активации – линейный выпрямитель (ReLU), пакетная нормализация, обнуление 10 % значений весов.	16x(Nx32)
5	Сверточный слой (Conv), функция активации – линейный выпрямитель (ReLU), пакетная нормализация, обнуление 10 % значений весов.	8x(Nx32)
6	Сверточный слой (Conv), функция активации – логистическая (Softmax), пакетная нормализация, обнуление 10 % значений весов.	16x(Nx2)
7	Выход (два канала значений детектирующей функции)	Nx2

Примечание: N – количество отсчетов сейсмической записи.

Краткое описание применяемых к весам СНС функций активации:

– линейная функция активации – переводит значения входа пропорционально выходным значениям: $f(x) = x$;

– функция активации гиперболическим тангенсом (Tanh) – переводит входные значения через гиперболический тангенс в промежуток $(-1;1)$: $f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$;

– функция активации линейным выпрямителем (ReLU) – обнуляет отрицательные значения входа: $f(x) = \max(0, x)$;

– логистическая функция активации (Softmax) – преобразует вектор входных значений в распределение вероятности: $f(x) = e^x / \sum_{j=1}^K x_j$. Элементы выходных значений лежат в диапазоне $(0;1)$ и их сумма равна 1.

Пакетная нормализация приводит значения каждого нейрона в диапазон $(0;1)$, тем самым ускоряя подбор весов СНС. При обучении во всех скрытых слоях СНС применяется процедура обнуления 10 % случайных значений весов на каждой эпохе обучения (dropout regularization). Применение этой процедуры позволяет предотвратить переобучение СНС [Srivastava et al., 2014]. Несмотря на то, что в алгоритме используется лишь один выходной канал, выход на два канала необходим для устойчивого обучения сверточной нейронной сети используемой архитектуры.

ПОДГОТОВКА ДАННЫХ И ОБУЧЕНИЕ НЕЙРОННОЙ СЕТИ ДЛЯ ДЕТЕКЦИИ СОБЫТИЙ

Перед применением алгоритма осуществляется предварительная обработка данных, она применяется ко всем записям, загружаемым в нейросеть, в т.ч. и к данным для обучения. Предварительная обработка данных заключается в удалении линий тренда, полосовой фильтрации (10–80 Гц) и нормировке в 100-секундном окне. Верхняя частота полосы пропускания обусловлена частотным

составом целевых локальных событий, а нижняя частота пропускания позволяет в значительной мере подавить сигналы сильных землетрясений с удаленными эпицентрами. Нормировка позволяет свести все превышения над фоном к одному уровню, позволяя нейросети не реагировать на значительные превышения амплитуды в областях неотфильтрованного шума.

Для обучения нейронной сети нужно создать размеченный массив данных, условно классифицирующий их с точки зрения наличия в записи сейсмического события в заданный момент времени. В дальнейшем мы более детально остановимся на наборе данных, использованном при обучении нейронной сети. Создание оптимальной разметки является важным этапом обучения нейронной сети, поэтому в рамках нашей работы исследуются разные способы разметки данных, которые можно условно поделить на два типа.

Первый тип разметки представляет собой набор значений 0.9999 на участках записи, соответствующих некоторому интервалу записи после прихода продольной волны, а на участках шума – 0.0001 (рис. 1) (функция типа «коробочки»). Выбраны значения близкие к 0 и 1, чтобы нейросеть в каждой временной точке решала задачу, схожую с классификацией, но не была ограничена лишь двумя классами и могла устанавливать промежуточные значения для временных точек. Форма такой разметки очень далека от формы самого сигнала. Сама разметка основывается на временах прихода продольных и поперечных волн (для размеченного набора данных они определялись сейсмологом «вручную») и рассматривается несколько вариантов ширины «коробочки»: либо используемая «коробочка» начинается во время прихода продольной волны, и заканчивается через некоторое заданное время (рассматривались три различных ширины 1.5, 2.5 и 4 с) после прихода поперечной волны (см. рис. 1); либо «коробочка» определяется симметричным окном относительно времени прихода поперечной волны, левый край окна соответствует времени прихода продольной волны (см. рис. 1). Сама разметка присваивается ко всем трем компонентам одновременно.

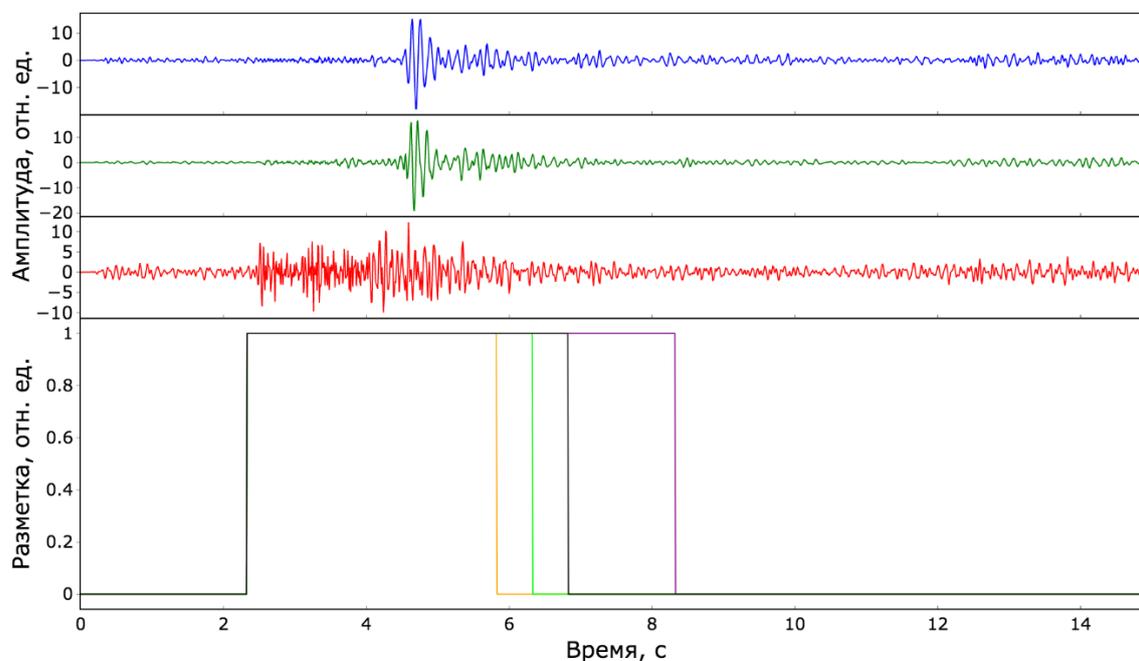


Рис. 1. Различные разметки данных. Сверху представлена трехкомпонентная запись, в компоненты X, Z которой добавлены константы +2, –2 соответственно, предварительно запись отнормирована (аналогичный способ отображения используется в последующих рисунках). Ярко-зеленым обозначена разметка с адаптивным окном, оранжевым, черным и фиолетовым цветом обозначены статичные разметки с выносом правого края относительно времени прихода поперечной волны соответственно на 1.5, 2.5 и 4 секунды

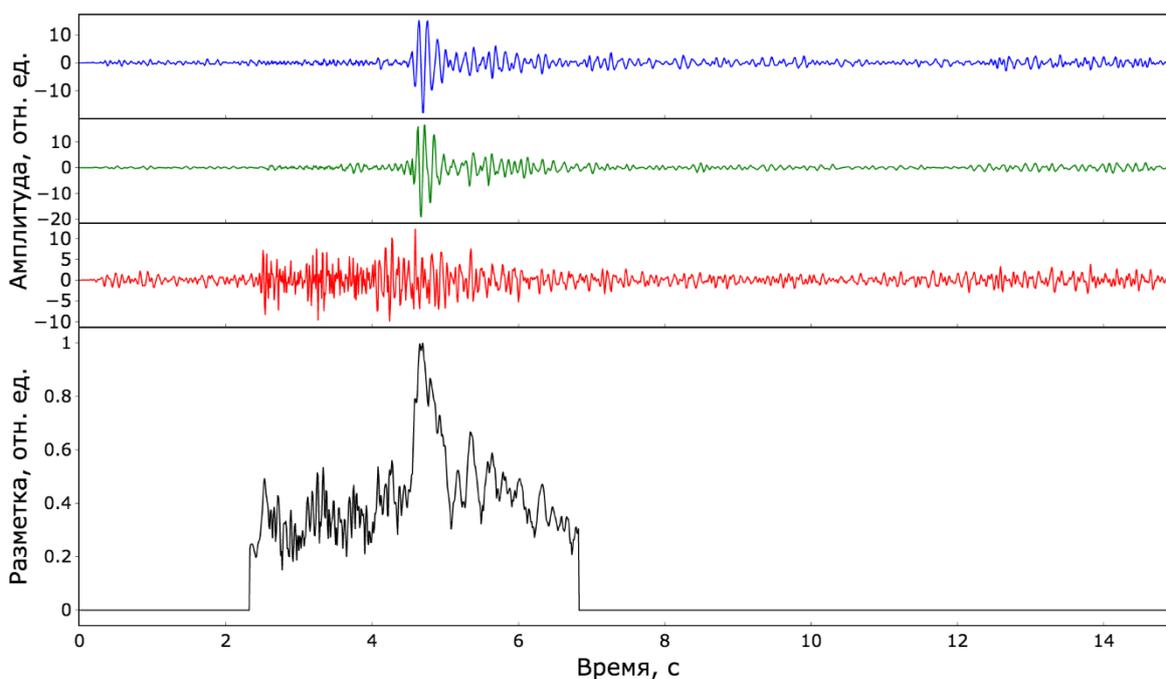


Рис. 2. Разметка, основанная на огибающих трасс

Второй тип разметки основывается на функции огибающей сигнала. В каждой точке считается корень из суммы значений огибающих трасс, после чего полученное значение умножается на «коробочку» (рис. 2). Умножение на «коробочку» производится для того, чтобы нейросеть обучалась детектировать события только в тех местах, где они детектируются вручную и для них можно определить времена прихода волн. При этом случайные высокоамплитудные помехи не оказывают эффект на обучение.

Обучение нейронной сети представляет собой подбор весовых функций на нейронах слоев с целью минимизации ошибки между получаемым нейросетью результатом и используемой для обучения разметкой данных. С этой целью вводится функционал невязки, основанный на среднеквадратическом отклонении между требуемым и получаемым результатом. Если величина функционала перестает убывать, это означает, что нейронная сеть перестает улучшать приближение своего решения к разметке.

Для обучения были взяты 700 15-секундных отрезков записи, содержащих сигналы от землетрясений с магнитудой от 0 до 3 (Ml) с определенными временами прихода продольных и поперечных волн для локальной сейсмической сети из Прикаспийской низменности. Отношение длин отрезков времени, содержавших сигнал от событий к длине отрезков времени записей шума, составляет в среднем 1 к 4, что оказалось оптимальным соотношением для обучения. Содержание сигнала на менее 5 % записей приведет к быстрому приходу нейросети к устойчивому нулевому решению, а содержание более 50 % приводит к повышенной чувствительности нейросети к шуму.

В ходе тестов различных разметок было выявлено, что величина функционала убывает в течение 2000 эпох обучения (рис. 3). Несмотря на то, что каждое обучение уникально, графики функционала практически накладываются друг на друга. При оценке результативности обнаружилось, что наилучший результат в разделении сигнала и шума показывают нейронные сети, обучавшиеся 500 и 900 эпох. Результатом обучения нейронной сети становится ее способность давать детектирующую функцию в виде некоторого значения от 0 до 1 в каждой временной точке по отдельной записи, таким образом отделяя

области событий от областей фона на всем ее протяжении (рис. 4). Сравнение результатов обучения с использованием различных разметок было проведено для нейронных сетей, обучавшихся в течение 900 эпох (см. рис. 4). Детектирующая функция оранжевого цвета (соответствует запаздыванию правого края окна 1.5 с) определяет событие самым коротким поднятием, при этом давая самый высокий ложный пик (справа) в области увеличенного фонового шума среди всех разметок, пусть и более короткий по времени. Детектирующая функция для самого длинного окна разметки (фиолетового цвета) дает самое продолжительное поднятие для события, но в области шумов показывает наибольшие значения наряду с детектирующей функцией, основанной на адаптивном временном окне детекции (ярко-зеленая). Детектирующая функция, использующая задержку 2.5 с (показана черным цветом), показывает наименьший уровень детектирующей функции в области шума. Аналогичная ситуация наблюдается на различных сейсмограммах. При тестировании разметки, использующей энергию сигнала, окно, на которое умножались значения разметки, выбиралось по результатам тестирования разметок выше (2.5 с). Обучение нейронной сети на втором типе разметки происходило дольше – 1500 эпох. Обучение с использованием такой разметки дает детектирующие функции с более низким отделением сигнала от фона, однако и ложные пики на ней ниже и соотношение сигнал/шум в целом получается выше (рис. 5).

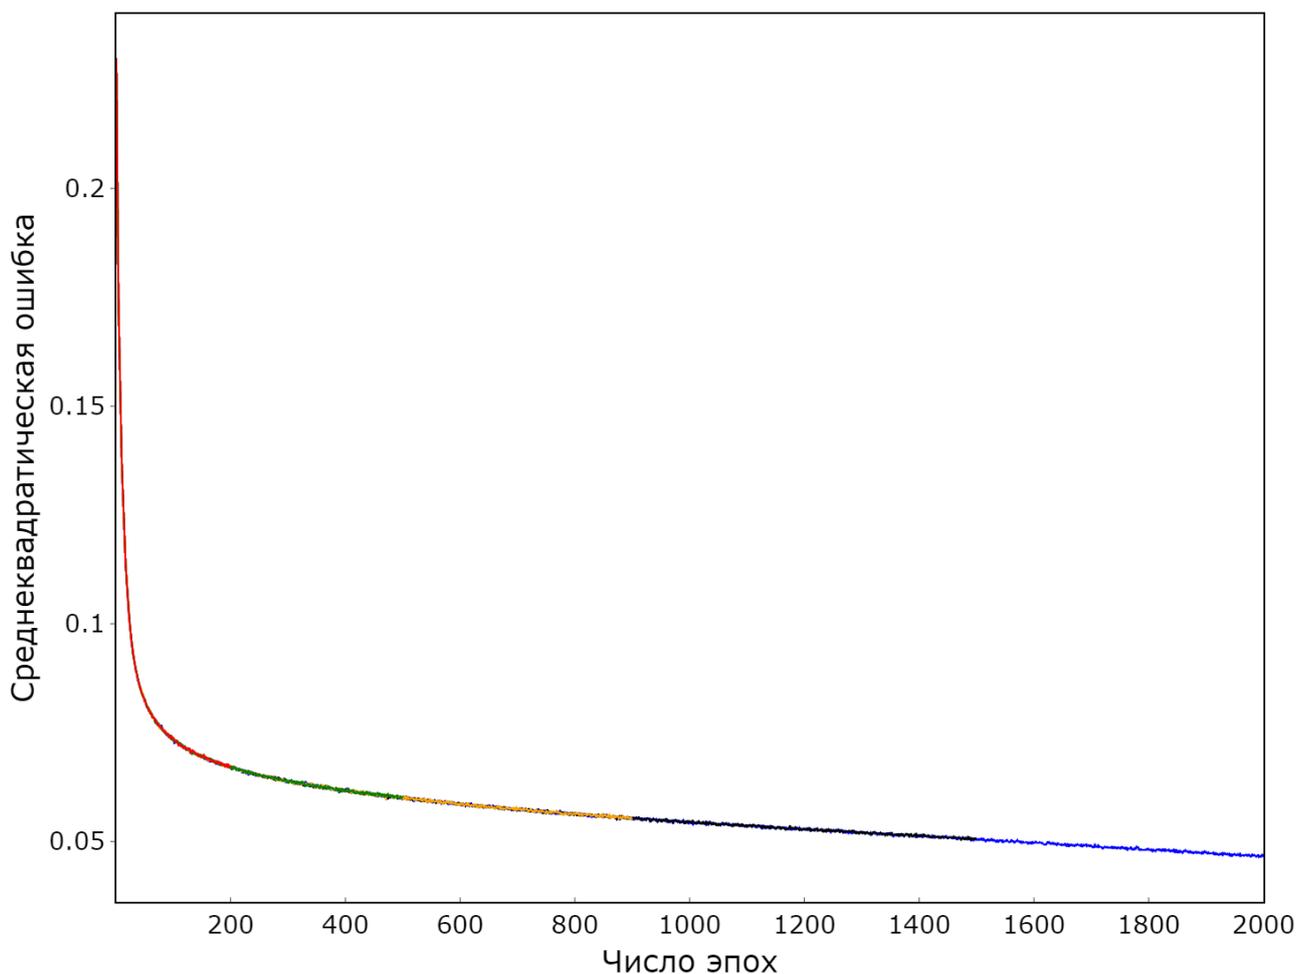


Рис. 3. Снижение среднеквадратического отклонения для 5 нейросетей, обучаемых в течение 200 (красный), 500 (зеленый), 900 (желтый), 1500 (черный) и 2000 (синий) эпох

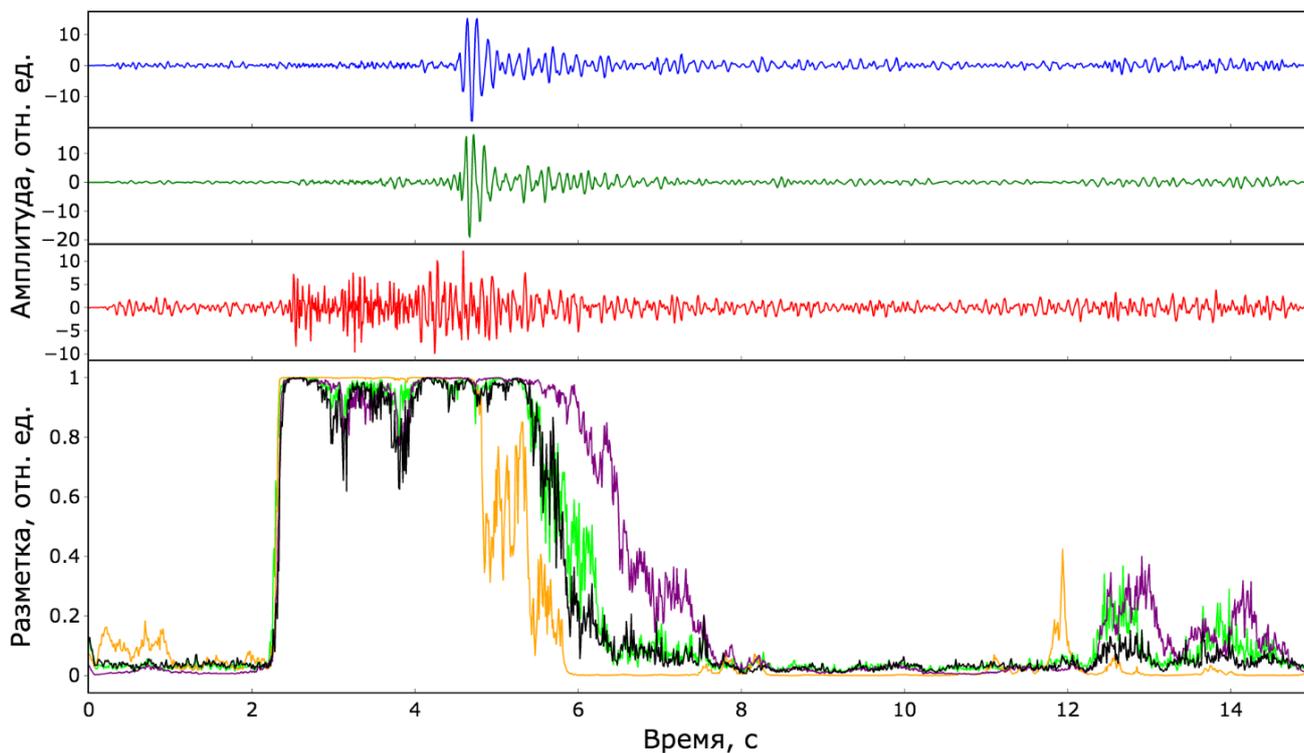


Рис. 4. Примеры детектирующих функций, обученных на разных разметках. Цвета детектирующих функций соответствуют цветам разметок, использованных на рис. 1: с запаздыванием правого края относительно времени прихода поперечной волны: фиолетовая на 4 с, черная – 2.5 с, оранжевая – 1.5 с, ярко-зеленая – с адаптивным окном

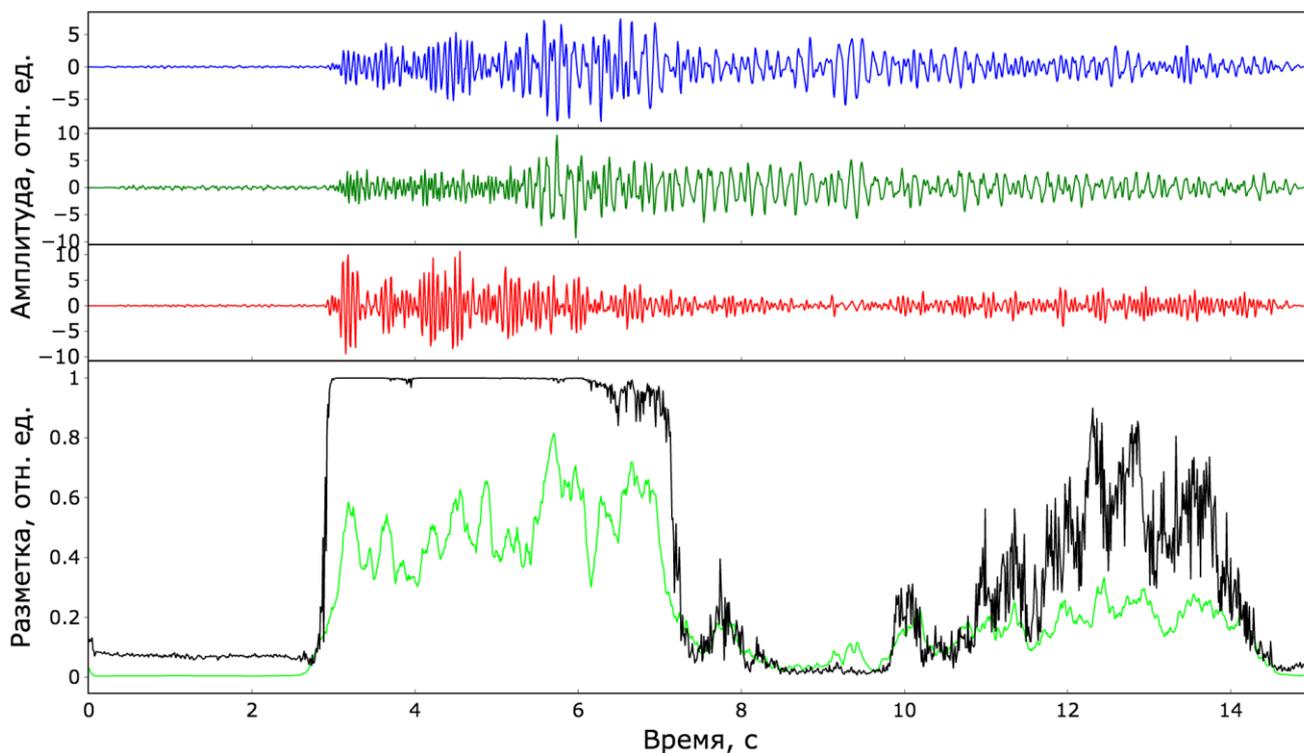


Рис. 5. Сравнение использующей амплитуду сигнала (зеленым) разметки и не использующей (черным) на отдельной записи

ОБРАБОТКА ДАННЫХ СЕТИ СТАНЦИЙ

Принципом работы MER [Coppens et al., 1985] на сейсмограммах является сопоставление триггеров на синхронных записях, где пересечение более трех из них в одном временном окне на записях разных сейсмоприемников обозначает детектированное событие. Для работы с результатами нейросети была использована детектирующая функция сети (ДФС). Принципом работы ДФС является вычисление среднего значения детектирующих функций по всем синхронным в каждой временной точке. После расчета ДФС для всех временных точек ее превышения над определенным средним значением отмечаются как триггеры. Продолжительность определения событий на записях для локальных сетей сейсмических станций обычно значительно больше, чем разница во временах прихода на разных станциях, поэтому можно использовать суммирование по отдельной временной точке для детектирования. Таким образом отсекаются ложные пики детектирующей функции на отдельных записях, а соответствующие событиям участки накладываются, давая пики детектирующей функции сети.

ТЕСТИРОВАНИЕ НЕЙРОННОЙ СЕТИ И СРАВНЕНИЕ С MER

Для сравнения с MER были использованы специально выбранные 67 часовых сейсмограмм с частотой дискретизации 5 мс, включающих записи 69 событий с магнитудами от 0.4 до 1.6 (Ml) и различной интенсивности для анонимизированной локальной сети (отличной от использованной при обучении), включающей семь станций (рис. 6), там же представлена геометрия станций сети, использованной при обучении нейросети. Скорость выполнения детектирования на этом наборе показала, что разработанный алгоритм обрабатывает его примерно в 2 раза медленнее, чем MER.

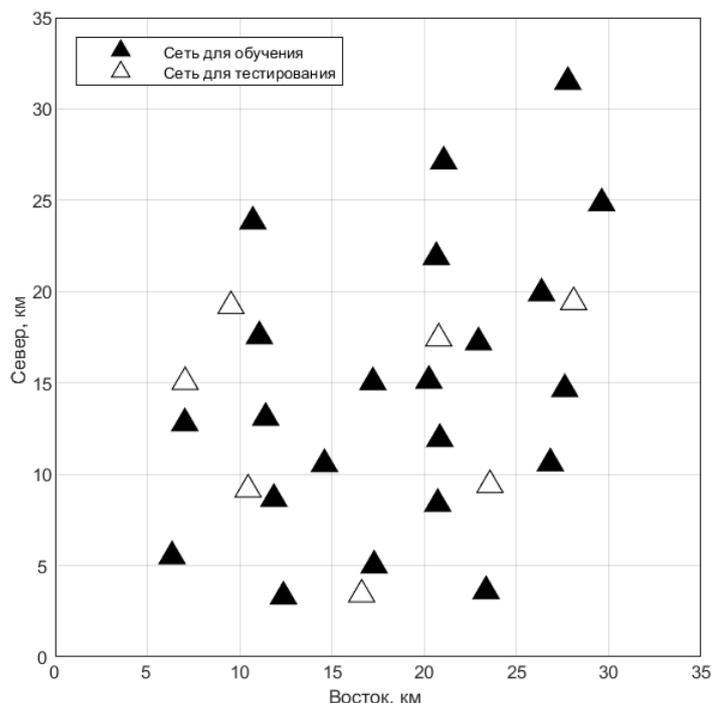


Рис. 6. Схематическая визуализация геометрий систем наблюдений (вид в плане). Две системы наблюдений (черные и белые треугольники обозначают сеймостанции из разных систем наблюдений) расположены на расстоянии нескольких сотен километров друг от друга, но наложены одна на другую для оценки относительных размеров

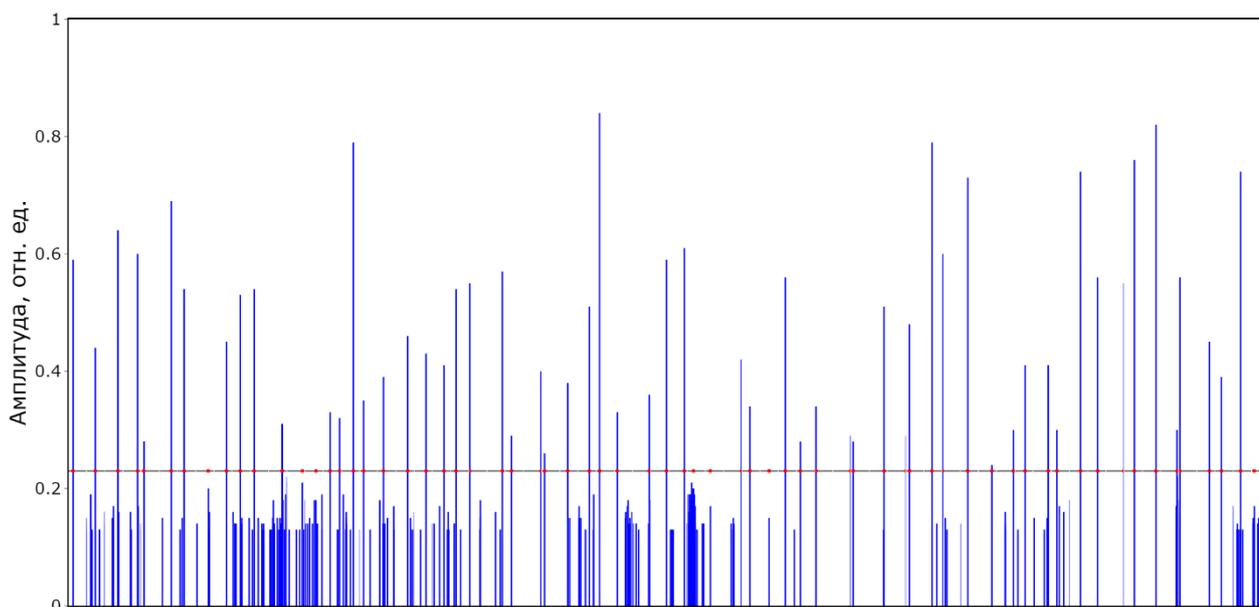


Рис. 7. Пример детектирующей функции для 67 сейсмограмм

Результаты детектирования, приведенные в табл. 2, показали, что при пониженных уровнях детектирования нейронная сеть способна задетектировать все события при ограниченном количестве ложных срабатываний, однако для сравнения с MER были выбраны повышенные отсекающие уровни, в связи с тем, что при них число задетектированных землетрясений у сравниваемых методов максимально близко. Однако количество ложных срабатываний в значительной степени отличается: если у ДФС они практически отсутствуют при детектированных 64 событиях, то MER при 62 определенных событиях дает также 31 ложное детектирование. Для ДФС на рис. 7 приведена статистика детектирования по всему набору данных.

Таблица 2

Статистика детектирования событий для MER и ДФС

	MER	ДФС (0.14)	ДФС (0.13)	ДФС (0.11)	ДФС (0.10)
Найденные	62/69	64/69	66/69	68/69	69/69
Пропущенные	7	5	3	1	0
Ложные	31	1	4	23	50

ВЫВОДЫ

В работе представлен алгоритм детекции слабых землетрясений на трехкомпонентных записях, основанный на применении методов машинного обучения. Сам алгоритм предполагает простую предобработку данных в виде предварительной фильтрации и нормировки записи.

В работе приведена архитектура нейронной сети, которая включает пять сверточных слоев и другие компоненты. Обучение нейронной сети для используемого набора показывают стабильный результат после 1500 эпох обучения. Важной частью разработки алгоритма является разметка данных при обучении нейронной сети. Для обучения нейросети использовалось 700 15-секундных записей землетрясений, полученных для локальной сейсмической сети. Было показано, что оптимальным способом разметки из изученных оказалось умножение суммарной энергии трехкомпонентного сейсмоприемника, определенной по огибающим записей каждой из компонент, на окно типа «коробочка»

с левым краем на времени прихода продольной волны, а правым краем, расположенным через 2.5 с после прихода поперечной волны.

В комбинацию к результатам нейронной сети для индивидуальных сейсмоприемников была использована модифицируемая детектирующая функция сети, которую можно настраивать в соответствии с требуемой чувствительностью детектирования событий. Реализованный алгоритм детектирования показывает хорошую результативность в тестах на наборе непрерывных данных (не использованных при обучении для другой локальной сети) – лучшую точность в детектировании событий на специальной тестовой выборке с этой же сети, чем MER, статистика чего приведена в работе.

Для обработки записей с высоким соотношением сигнал/шум в дополнение к детектированию развиваются алгоритмы определения времен прихода волн, основанные на использовании сверточных нейронных сетей [Guo et al., 2020], и эти алгоритмы показывают лучшую точность.

Исследование выполнено при финансовой поддержке РФФИ и Правительства Новосибирской области в рамках проекта № 19-45-540007. Авторы благодарны рецензенту А.В. Лисейкину за ценные замечания к работе.

ЛИТЕРАТУРА

Дергач П.А., Логинов Г.Н. Алгоритм детектирования сигналов от слабых локальных землетрясений на основе сверточной нейронной сети: пример обработки реальных данных и сравнение с классическим методом // Современные методы оценки сейсмической опасности и прогноза землетрясений: Всероссийская научная конференция с международным участием (г. Москва, 27–28 ноября 2019 г.): Тезисы докладов и программа конференции. – М.: ИТПЗ РАН, 2019. – С. 40–41.

Еманов А.Ф., Еманов А.А., Лескова Е.В., Фатеев А.В., Семин А.Ю. Сейсмические активизации при разработке угля в Кузбассе // Физическая мезомеханика. – 2009. – Т. 12, № 1. – С. 37–43.

Землетрясения и микросейсмичность в задачах современной геодинамики Восточно-Европейской платформы // Под ред. Шарова Н.В., Маловичко А.А., Щукина Ю.К. Кн. 2: Микросейсмичность. – Петрозаводск: Карельский научный центр РАН, 2007. – 96 с.

Логинов Г.Н., Дучков А.А., Литвиченко Д.А., Аляжкин С.А. Пример применения сверточных нейронных сетей в обработке реальных данных 3D сейсморазведки // Интерэкспо ГЕО-Сибирь: XV Междунар. науч. конгр. (г. Новосибирск, 24–26 апреля 2019 г.): Междунар. науч. конф. «Недропользование. Горное дело. Направления и технологии поиска, разведки и разработки месторождений полезных ископаемых. Экономика. Геоэкология»: Сборник материалов в 9 т. – Новосибирск, 2019. – Т. 2, № 3. – С. 147–153.

Пузырев Н.Н. Методы и объекты сейсмических исследований. Введение в общую сейсмологию. – Новосибирск: СО РАН, 1997. – 301 с.

Akram J., Ovcharenko O., Peter D. A robust neural network-based approach for microseismic event detection // SEG Technical Program Expanded Abstracts. – 2017. – P. 2929–2933, doi: 10.1190/segam2017-17761195.1.

Coppens F. First arrivals picking on common-offset trace collections for automatic estimation of static corrections // Geophysical Prospecting. – 1985. – Vol. 33 (8). – P. 1212–1231, doi: 10.1111/j.1365-2478.1985.tb01360.x.

Guo C., Zhu T., Gao Y., Wu S., Sun J. AEnet: Automatic Picking of P-Wave First Arrivals Using Deep Learning // IEEE Transactions on Geosciences and Remote Sensing. – 2020. – Vol. 59 (6). – P. 5293–5303, doi: 10.1109/TGRS.2020.3010541.

Srivastava N., Hinton G., Krizhevsky A., Sutskever I., Salakhutdinov R. Dropout: a simple way to prevent neural networks from overfitting. Journal of Machine Learning Research. – 2014. – Vol. 15 (1). – P. 1929–1958.

REFERENCES

- Akram J., Ovcharenko O., Peter D.** A robust neural network-based approach for microseismic event detection // SEG Technical Program Expanded Abstracts. – 2017. – P. 2929–2933, doi: 10.1190/segam2017-17761195.1.
- Coppens F.** First arrivals picking on common-offset trace collections for automatic estimation of static corrections // Geophysical Prospecting. – 1985. – Vol. 33 (8). – P. 1212–1231, doi: 10.1111/j.1365-2478.1985.tb01360.x.
- Dergach P.A., Loginov G.N.** An algorithm for detecting signals from weak local earthquakes based on a convolutional neural network: an example of real data processing and comparison with the classical method // Modern methods of seismic hazard assessment and earthquake prediction: Russian scientific conference with international participation (Moscow, November 27–28, 2019): Abstracts and conference program. – Moscow, 2019. – P. 40–41.
- Earthquakes** and microseismicity in problems of contemporary geodynamics of the East European Platform, in: Sharova N.V., Malovichko A.A., Shchukina Yu.K. (Eds.). Book. 2: Microseismicity. – Petrozavodsk, Karelian Scientific Center of the Russian Academy of Sciences, 2007. – 96 p.
- Emanov A.F., Emanov A.A., Leskova E.V., Fateev A.V., Semin A.Yu.** Seismic activations during coal mining in Kuzbass // Physical Mesomechanics. – 2009. – Vol. 12 (1). – P. 37–43.
- Guo C., Zhu T., Gao Y., Wu S., Sun J.** AEnet: Automatic Picking of P-Wave First Arrivals Using Deep Learning // IEEE Transactions on Geosciences and Remote Sensing. – 2020. – Vol. 59 (6). – P. 5293–5303, doi: 10.1109/TGRS.2020.3010541.
- Loginov G.N., Duchkov A.A., Litvichenko D.A., Alyamkin S.A.** An example of using convolutional neural networks in real 3D seismic data processing // Interexpo GEO-Siberia: XV Intern. Scientific. Congr. (Novosibirsk, April 24–26, 2019): Intern. Scientific. conf. "Subsoil use. Mining. Directions and technologies of prospecting, exploration and development of mineral deposits. Economy. Geoecology": Collection of materials in 9 volumes. – Novosibirsk, 2019. – Vol. 2, No. 3. – P. 147–153.
- Puzyrev N.N.** Methods and objects of seismic investigation. Introduction to general seismology [in Russian]. – Novosibirsk: SB RAS, 1997. – 301 p.
- Srivastava N., Hinton G., Krizhevsky A., Sutskever I., Salakhutdinov R.** Dropout: a simple way to prevent neural networks from overfitting. Journal of Machine Learning Research. – 2014. – Vol. 15 (1). – P. 1929–1958.

КОРОТКО ОБ АВТОРАХ

УЛЬЯНОВ Николай Анатольевич – студент магистратуры ГГФ НГУ. Основные научные интересы: обработка и анализ сейсмических данных, локальная сейсмология.

ЯСКЕВИЧ Сергей Владимирович – кандидат физико-математических наук, старший научный сотрудник лаборатории комплексной геофизики ИЗК СО РАН. Основные научные интересы: обработка и анализ сейсмических данных.

ДЕРГАЧ Петр Александрович – научный сотрудник лаборатории динамических проблем сейсмики ИНГГ СО РАН. Основные научные интересы: локальная сейсмология и инженерная сейсморозведка.

ЯБЛОКОВ Александр Викторович – научный сотрудник лаборатории динамических проблем сейсмики ИНГГ СО РАН. Основные научные интересы: развитие алгоритмов спектрального анализа и решения обратной задачи сейсмики с использованием вейвлет-разложения и машинного обучения для обработки данных поверхностных волн.

*Статья поступила в редакцию 1 сентября 2021 г.,
принята к публикации 22 октября 2021 г.*