

ОБНАРУЖЕНИЕ СЕЙСМИЧЕСКИХ СОБЫТИЙ НА ОСНОВЕ ИСКУССТВЕННОЙ НЕЙРОННОЙ СЕТИ SeisDetNet. ЧАСТЬ 2. АПРОБАЦИЯ МОДЕЛИ

© 2025 С.А. Имашев, А.В. Аладьев

Научная станция РАН в г. Бишкеке, Бишкек, Кыргызстан, 720049;
e-mail: sanzhar.imashev@gmail.com

Поступила в редакцию 19.07.2024 г.; после доработки 05.03.2025 г.; принята в печать 25.03.2025.

На основе комбинации сверточной и полносвязной нейронных сетей была разработана модель SeisDetNet, предназначенная для разделения сейсмических событий и сейсмического шума по записям волновых форм. Для обнаружения сейсмических событий в непрерывных записях произвольной продолжительности предложен алгоритм, анализирующий волновые формы в скользящем окне: на вход нейронной сети SeisDetNet подаются последовательные участки длиной в 1 минуту, а на выходе формируется ряд вероятностей наличия сейсмического события в анализируемом участке. Расширение этого алгоритма для анализа записей с нескольких сейсмических станций показало хорошие результаты. В частности, модель успешно обнаружила все события из сейсмического каталога KNET Научной станции РАН за январь–март 2024 года, включая землетрясения малого энергетического класса ($K \leq 7$). Также апробация модели в задаче обнаружения афтершоков сильного Учтурфанского землетрясения с $M_w=7$, произошедшего 22.01.2024 г. в 18:09 UTC на границе Китая и Кыргызстана, показала результаты, сопоставимые с ручной обработкой.

Ключевые слова: сейсмическое событие, нейронная сеть, волновые формы, афтершоки.

ВВЕДЕНИЕ

Одним из подходов для комплексного анализа данных сейсмического мониторинга с помощью методов машинного обучения является разделение процесса обработки на несколько этапов. На первом этапе выделяются сейсмические события, которые формируются в так называемые «вырезы» и передаются на следующие стадии обработки, такие как пикирование фаз сейсмических волн, оценка магнитуды и эпицентрального расстояния. Например, в работе (Zhou et al., 2019) комплексная обработка сейсмических данных реализована с помощью гибридной нейронной сети, состоящей из двух последовательных моделей. Первая сеть (DetNet), основанная на одномерных сверточных слоях, выполняет выделение сейсмических событий. Затем участок, классифицированный как содержащий сейсмическое событие, передается во вторую рекуррентную нейронную сеть (PpkNet), построенную на ячейках GRU (Chung et al.,

2014), для определения моментов вступления P- и S-волн.

Разделение задач на специализированные нейросетевые модели имеет несколько ключевых преимуществ по сравнению с использованием одной большой комплексной нейронной сети для выполнения нескольких задач. Во-первых, это дает упрощение процесса обучения и снижение сложности модели. Так как каждая из специализированных моделей обучается решать одну конкретную задачу, то это в целом упрощает весь процесс обучения. Например, нейросетевая модель, предназначенная для обнаружения сейсмических событий, проще как по архитектуре, так и по количеству обучаемых параметров и, следовательно, производительнее, чем модель, одновременно выполняющая и обнаружение, и определение фаз P- и S-волн (Münchmeyer et al., 2022). Для сравнения, оценка количества обучаемых параметров модели PhaseNet, исходя из оригинальной статьи (Zhu, Beroza, 2016), дает значение ~ 260000 , тогда как SeisDetNet (Имашев,

Аладьев, 2024) содержит всего ~31000. Во-вторых, модульный подход обеспечивает относительную гибкость и адаптивность к новым задачам, при которых легче заменять или обновлять одни модели, не затрагивая при этом другие. Например, если блок, отвечающий за обнаружение сейсмических событий, улучшается за счет развития методики или привлечения дополнительных данных, то, появляется возможность обновления только этой части системы. Также, легче добавить новую задачу (например, оценку магнитуды или эпицентрального расстояния) в виде отдельной модели, чем интегрировать ее в уже существующую сложную модель. В-третьих, такие системы лучше масштабируются, так как отдельные компоненты могут работать параллельно и оптимизироваться независимо друг от друга. Такой подход также устойчив к сбоям, так как если одна из моделей выходит из строя или работает некорректно, это не приводит к сбою всей системы, так как другие нейронные сети могут продолжать работать в штатном режиме. Также для определенного круга задач может не потребоваться детальная информация о фазах сейсмической волны, а только лишь наличие факта сейсмического события. Примерами таких задач могут быть исследования наведенной сейсмичности, например, изучение микросейсмических откликов геосреды на инициирующее воздействие в виде сеансов зондирования мощными импульсами тока (Имашев, Рыбин, 2023) или иных внешних воздействий, например, солнечных вспышек и магнитных бурь (Гульельми и др., 2015; Сычева, 2022).

В настоящей работе рассматривается методика обнаружения сейсмических событий в непрерывной записи произвольной продолжительности с помощью сети SeisDetNet (Имашев, Аладьев, 2024), а также апробация этого алгоритма на данных сейсмического каталога сети KNET Научной станции РАН (НС РАН) и афтершоковой последовательности Учтурфанского землетрясения магнитудой $M_w=7$, произошедшего 22.01.2024 г. на границе Кыргызстана и Китая (Соколова и др., 2024). Предлагаемая модель и сопутствующие алгоритмы могут быть использованы в комплексной системе сейсмического мониторинга в задачах предварительного выделения сейсмических событий для последующей обработки и анализа, например, определения фаз, оценки магнитуды и эпицентрального расстояния.

ДААННЫЕ СЕЙСМИЧЕСКИХ СОБЫТИЙ

Для апробации модели был использован сейсмологический каталог сети KNET за 1-квартал 2024 года и данные с 7 сейсмических станций KNET НС РАН (ААК, КВК, ТКМ2, ULHL, USP,

СНМС, ЕКС2) (Сычева, 2016), а также данные с сейсмических станций сети KNET (<http://ds.iris.edu/mda/KR>) Института сейсмологии Национальной академии наук Кыргызской Республики (ИС НАН КР), полученные посредством FDSN клиента Центра Управления Данными IRIS (<https://service.iris.edu/fdsnws/>).

МЕТОДИКА

Поскольку на практике обнаружение сейсмических событий и шума необходимо производить в непрерывной записи волновой формы произвольной продолжительности (Münchmeyer et al., 2021), было решено смоделировать эти записи в виде 100 искусственных временных рядов со случайным включением 5 записей сейсмического события и 15 записей сейсмического шума. При этом нужно отметить, что примеры извлекались случайным образом из тестовой выборки, которую модель SeisDetNet не использовала на этапе обучения. Все сгенерированные варианты имели одинаковые характеристики, поэтому рассмотрим их на примере одной реализации (рис. 1). Общая продолжительность временного ряда составила 120000 отсчетов. На вход нейронной сети в скользящем окне (выделено цветом и прямоугольной областью) подавались три участка волновых форм (по каждому из каналов E, N, Z — восточная, северная и вертикальная компоненты), которые предварительно нормализовались и преобразовывались в трехканальную спектрограмму.

На выходе модели формируется временной ряд P_m , представляющий вероятность появления сейсмического события в следующих 6000 отсчетах (рис. 2б). Далее задается значение границы разделения классов (горизонтальная линия на рис. 2б) и применяется правило бинарной классификации к временному ряду P_m . Исходя из анализа результатов работы нейронной сети на тестовой выборке (Имашев, Аладьев, 2024) в качестве оптимального значения границы разделения классов (сейсмическое событие или шум) было выбрано значение, равное 0.3. В результате формируется временной ряд C_m , состоящий из значений 0 и 1, где области с группировкой единиц указывают на участки, где модель идентифицировала сейсмическое событие (рис. 2в). Отметим, что значения P_m и C_m относятся ко времени начала окна, которое в данном случае перемещается с шагом 100 отсчетов (1 секунда).

Далее, на основании границ групп, содержащих 0 или 1, вырезаются участки, содержащие волновые формы сейсмических событий (рис. 2а, закрашенные области).

Анализ выделенных участков, содержащих сейсмическое событие показывает, что




Рис. 1. Искусственная запись с включением 5 сейсмических событий в 20 минутный сейсмический шум. Отрезки сейсмических событий и шума взяты из тестовой выборки. Окно для извлечения данных, подаваемых на вход модели, выделено цветом и прямоугольной областью. E, N и Z — три ортогональные компоненты (восточная, северная и вертикальная) сейсмического сигнала в виде отсчетов амплитуды.

Fig. 1. Synthetic record containing 5 seismic events embedded within 20-minute seismic noise. Seismic event and noise segments are taken from the test dataset. The window for extracting data fed to the model input is highlighted with colored rectangular area. E, N, and Z represent the three orthogonal components (east, north, and vertical) of the seismic signal in amplitude counts.





Рис. 2. Результаты работы нейронной сети на искусственной волновой форме: вертикальная компонента записи Z (область, идентифицированная как сейсмическое событие, выделена цветом) (а); временной ряд вероятности появления сейсмического события в последующие 6000 отсчетов P_m (горизонтальной линией задана граница разделения классов) (б); результат бинарной классификации C_m исходя из значений P_m и заданной границы раздела классов (0 — шум, 1 — сейсмическое событие) (в).

Fig. 2. Results of the neural network's performance on the synthetic waveform: vertical component of the record Z (the area identified as a seismic event is highlighted in color) (a); time series of probabilities P_m indicating the presence of a seismic event in the next 6000 samples (the horizontal line shows the class boundary threshold) (b); result of binary classification based on P_m values and the threshold (0 — noise, 1 — seismic event) (c).

вступления P-волн, рассчитанные классическим методом STA/LTA Карла Джонсона (Carl Johnson's STA/LTA) (Withers et al., 1998), находятся примерно в центре выделенного участка, однако их точное положение и длина участка варьируются (рис. 3).

Рис. 3. Участки волновых форм (компонента Z), идентифицированные нейронной сетью как содержащие сейсмическое событие. Вертикальные линии — моменты вступления P-волны по методу STA/LTA.

Fig. 3. Waveform segments (Z component) identified by the neural network as containing seismic events. Vertical lines mark P-wave arrival times determined using the STA/LTA method.



Здесь необходимо отметить, что выбор алгоритма (модификации STA/LTA или модели нейронной сети) для определения момента вступления P- и/или S-волн зависит от поставленной задачи, объема данных и требований к точности и производительности.

Расширение рассмотренной методики обнаружения сейсмических событий в непрерывной записи произвольной продолжительности с помощью сети SeisDetNet на случай обработки данных с нескольких станций имеет свои особенности и будет рассмотрено на примерах реальных сейсмических событий.

РЕЗУЛЬТАТЫ И ОБСУЖДЕНИЕ

Для проверки работы нейронной сети SeisDetNet для задачи выделения сейсмических событий на основе данных с нескольких сейсмических станций были выбраны: сейсмические события из регионального каталога сейсмологической сети KNET ИС РАН (Сычева, 2016); и сейсмические события, входящие в афтершоковую последовательность Учтурфанского землетрясения с магнитудой $M_w=7$, произошедшего 22.01.2024 г. на границе Кыргызстана и Китая (Абдыраева и др., 2024). Выбор этих событий для апробации работы нейронной сети SeisDetNet обусловлен несколькими причинами. Во-первых, региональный каталог сейсмических событий по данным сети KNET формируется ИС РАН и активно используется для различных научных исследований, включая изучение геодинамических процессов и глубинных структур Тянь-Шаня (Сычева, 2016). При этом сейсмические данные, полученные в рамках KNET, отражают специфические условия регистрации сигналов, включая особенности характеристик сейсмических волн, обусловленных геологической средой Тянь-Шаня и параметрами сейсмостанций. Соответственно, проверка работы SeisDetNet на этих данных позволяет оценить насколько корректно нейросеть справляется с локальными особенностями, такими как уровень шума и вариативность сейсмических сигналов. Во-вторых, включение в анализ Учтурфанского землетрясения позволяет оценить возможности автоматического обнаружения сейсмических событий с помощью нейросетевого подхода в условиях большого количества афтершоковых событий с плотным распределением во времени. Таким образом, комплексное тестирование, включающее проверку на региональном каталоге, а также на афтершоковой последовательности с высокой плотностью событий является важным этапом для адаптации модели SeisDetNet к реальным условиям сейсмического мониторинга для последующего практического применения.

Обнаружение событий из регионального каталога сети KNET. Для данной задачи были выбраны все сейсмические события по данным каталога KNET ИС РАН, произошедшие в первом квартале 2024 г. Для каждого события извлекались вырезы волновых форм с действующих станций сети KNET, так, чтобы начало записи приходилось за две минуты до наступления события, а конец — через четыре минуты после (итоговая длина записи составляла 6 минут). Эти записи подавались на вход нейронной сети для анализа проявления сейсмической волны в выходных данных модели. Анализ проводился с использованием скользящего окна длиной в одну минуту, которое сдвигалось на каждой итерации на 500 отсчетов (5 секунд). Для примера, рассмотрим результаты работы SeisDetNet для случая самого слабого и самого сильного землетрясений из указанного каталога (рис. 4).

Анализ временных рядов вероятностей P_m для каждой станции показывает, что нейронная сеть уверенно выделяет участки, содержащие сейсмическое событие, за исключением случая обработки записи самого слабого события на самой удаленной станции. Например, слабое событие достаточно хорошо выделяется по вариациям P_m на станциях USP, ULHL и TKM2, несмотря на то, что сами вступления фаз волн слабо выделяются на уровне шума.

В качестве критерия значимости сейсмического события для его отнесения к классу землетрясений была рассчитана сумма временных рядов вероятностей P_m ($\sum P_m$), полученных для записей с каждой станции. Пороговое значение установлено равным трем, что соответствует минимальному количеству станций, на которых должно быть зарегистрировано сейсмическое событие. Уровень, превышающий этот порог (выделен зеленым цветом) и будет определять область, содержащую сейсмическое событие. Так как модель анализирует данные на одну минуту вперед, последняя точка с высокой суммарной вероятностью показывает, что в следующие 6000 отсчетов модель все еще фиксирует следы сейсмического события. Вследствие этого, правая граница области искусственно увеличивается на одну минуту. Из сравнения форм суммарной вероятности для слабого и сильного событий можно сделать вывод о том, что слабое событие характеризуется более медленным ростом и меньшей площадью под кривой внутри рассчитанных границ сейсмического события.

Следует отметить, что из 230 сейсмических событий, зарегистрированных в каталоге KNET за период с января по март 2024 г., модель уверенно выделила все события. При этом порог минимального количества станций был установлен равным трем, хотя это значение можно

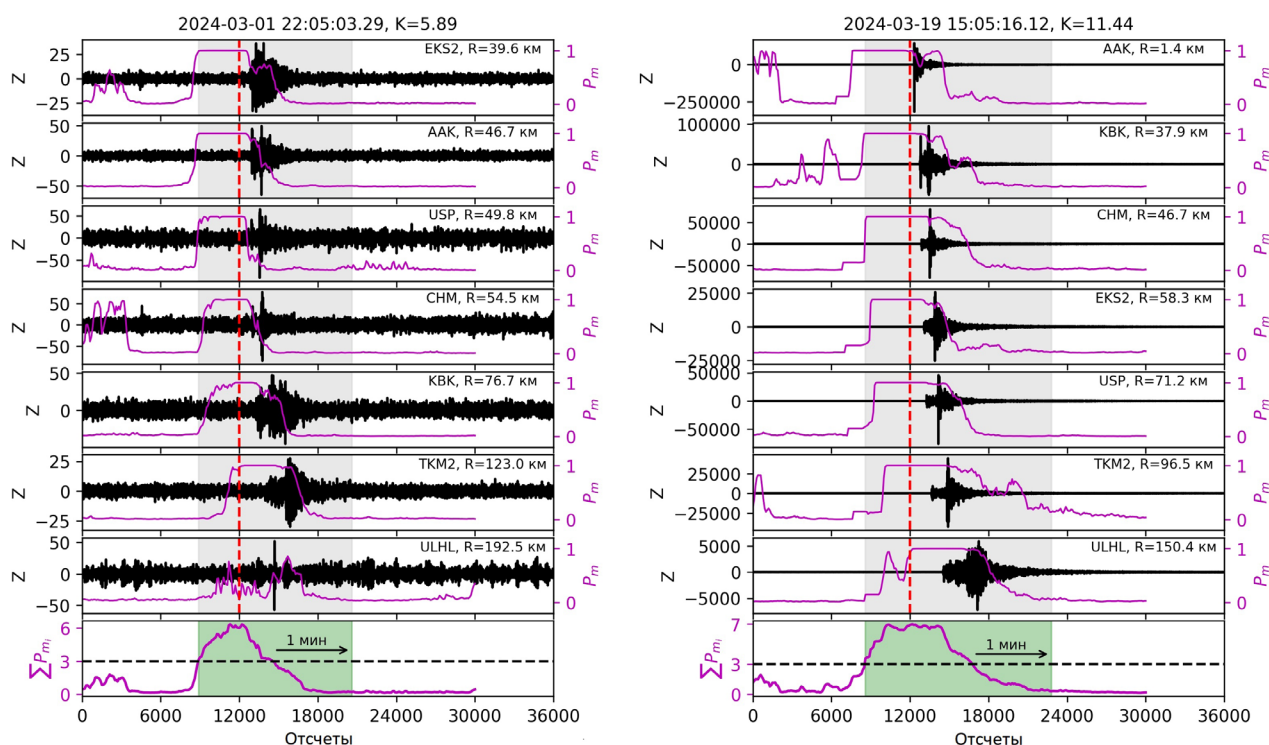


Рис. 4. Участки волновых форм (Z компонента) по станциям сети KNET, содержащие сейсмическое событие по результатам идентификации с помощью нейронной сети SeisDetNet (выделено закрашенной областью). Слева — самое слабое ($K=5.9$), справа — самое сильное ($K=11.4$). Черным — сейсмическая запись, малиновым — вероятность P_m (значение на выходе модели), красной вертикальной линией — момент сейсмического события. В нижних графиках ΣP_m по всем станциям.

Fig. 4. Waveform segments (Z component) from KNET network stations containing seismic events identified by the SeisDetNet neural network (highlighted in color). Left — the weakest event ($K=5.9$); right — the strongest event ($K=11.4$). Black curves represent the seismic record, magenta indicates the probability P_m (model output), and the red vertical line marks the moment of the seismic event. Lower graphs show ΣP_m across all stations.

варьировать в зависимости от того, землетрясения какого класса необходимо выделять в первую очередь. Стратегию обработки данных можно выстраивать так, чтобы сначала установить максимально высокий порог, а затем постепенно снижать его до минимального уровня, что будет зависеть от количества станций, участвующих в обработке.

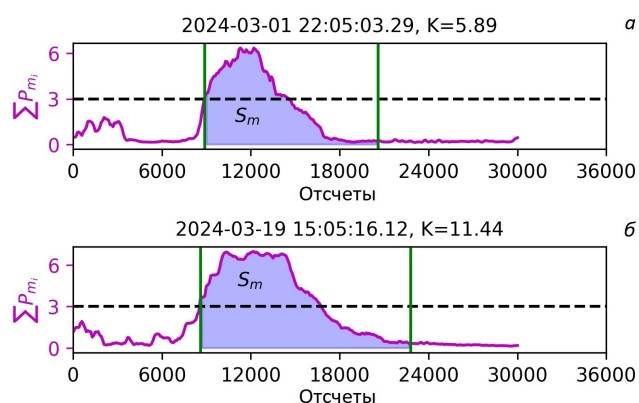
Анализ формы кривой суммы вероятностей показывает, что для слабых и умеренных событий площадь под кривой, ограниченной слева и справа границами сейсмического события S_m , коррелирует с энергетическим классом землетрясения. Например, слабое событие характеризуется меньшей продолжительностью и меньшей

Рис. 5. Сравнение суммарной вероятности ΣP_m по всем станциям KNET для слабого ($K=5.9$) (а) и сильного события ($K=11.4$) (б). S_m — площадь под кривой, ограниченной слева и справа границами сейсмического события.

Fig. 5. Comparison of the cumulative probability ΣP_m across all KNET stations for the weak event ($K=5.9$) (а) and the strong event ($K=11.4$) (б). S_m represents the area under the curve, bounded by the seismic event's left and right edges.

площадью S_m (рис. 5а), тогда как более сильное событие имеет более длительную продолжительность, и форма кривой дает большую площадь S_m (рис. 5б)

При этом значение площади S_m , рассчитанной для каждого из сейсмических событий, обнаруженных с помощью нейросети, будет определенным образом характеризовать общую энергию колебаний, вызванных этим землетрясением. Однако, зависимость значения энергетического класса сейсмического события K от площади S_m оказывается наиболее выраженной



для слабых и умеренных землетрясений с $K < 9$ (рис. 6).

Нарушение этой зависимости при $K > 9$ может быть связано с тем, что для сейсмических событий такой силы, модель уверенно присваивает значение 1 практически на всех станциях, что приводит к насыщению метрики S_m . Таким образом, вне зависимости от амплитуды сигнала, модель идентифицирует эту область как сейсмическое событие. Использование поправочного коэффициента, учитывающего амплитуду сигнала, позволяет скорректировать сильные события, сдвинув их вправо и одновременно сократив диапазон вариаций по оси ординат. В качестве поправочной величины можно применять среднее значение стандартного отклонения по каналу Z для участков, содержащих сейсмическое событие, рассчитанное по всем станциям σ_{mean} (рис. 7).

Наличие такой зависимости дает основание для использования существующей конфигурации нейронной сети с небольшой модификацией для предварительной оценки энергетического класса анализируемого сейсмического события. В работе (Münchmeier et al., 2021) было показано, что модель, основанная на нескольких сверточных слоях с добавлением слоев объединения (pooling) и финального полносвязного слоя, способна успешно выделять ключевые признаки для корректной оценки магнитуды по сейсмограммам. Такой подход продемонстрировал эффективность для ряда сейсмически активных регионов, таких как Чили, Италия и Япония.

Следующим этапом проверки является оценка эффективности нейросети в распознавании слабых и близко расположенных событий, особенно в условиях высокой сейсмической активности, например, когда наложение афтершоков друг на друга может создавать сложные сочетания сейсмических сигналов. В таких случаях нейросетевой подход к обнаружению сейсмических событий может повысить эффективность автоматизированного мониторинга, сокращая время анализа по сравнению с традиционными методами ручной обработки сейсмических данных.

Обнаружение афтершоковых событий Учтурфанского землетрясения. Учтурфанское землетрясение магнитудой $M_w = 7$ ($K = 15.5$), произошедшее 22 января 2024 г. в 18:09 UTC, недалеко от границы Кыргызстана и Китая (в уезде Уши (Учтурфан)), сопровождалось значительным количеством афтершоков, которое на конец февраля составляло уже 2882 события (Абдыраева, 2024). Поскольку это землетрясение и его афтершоки находятся за пределами зоны покрытия сети KNET, предназначенной для сейсмологического мониторинга территории

Бишкекского геодинимического полигона (БГП), в каталоге KNET события этого роя отсутствуют. Отметим, что к БГП относится территория, лежащая в пределах центрального сегмента Северо-Тянь-Шаньской сейсмогенерирующей зоны и представляет собой зону сочленения Тянь-Шаньского орогена и Туранской плиты (Баталева, Мухамадеева, 2018). Тем не менее, выделение подобных событий представляет интерес для




Рис. 6. Зависимость энергетического класса сейсмического события K , обнаруженного с помощью нейронной сети от площади S_m , рассчитанной по кривой суммы вероятностей $\sum P_m$ по всем станциям. Область, выделенная прямоугольником соответствует событиям с $K > 9$.

Fig. 6. Dependence of the energy class of a seismic event K , detected using the neural network, on the area S_m , calculated from the curve of the sum of probabilities $\sum P_m$ for all stations. The area marked with a rectangle corresponds to events with $K > 9$.




Рис. 7. Зависимость энергетического класса сейсмического события K , обнаруженного с помощью нейронной сети от площади S_m с поправочным коэффициентом σ_{mean} , учитывающим амплитуду сейсмического сигнала

Fig. 7. Dependence of the energy class of a seismic event K , detected using the neural network, on the area S_m with a correction factor σ_{mean} , taking into account the amplitude of the seismic signal

оценки работы модели, особенно учитывая, что база данных STEAD включает только локальные события, находящиеся на расстоянии менее 350 км от регистрирующей станции.

Для данной задачи были выбраны суточные волновые формы со всех действующих станций сети KRNET (<http://ds.iris.edu/mda/KR>) и KNET за период с 22 по 31 января 2024 г. Эти записи были поданы на вход SeisDetNet, в результате чего для каждой станции были получены временные ряды вероятностей P_m . Суммирование этих вероятностей по всем действующим станциям показало, что после главного толчка, произошедшего 22 января 2024 г. в 18:09 UTC, количество сейсмических событий, обнаруженных нейросетью возросло существенно (рис. 8).

После этого, задав границу минимального количества станций N_s равной, например, 8 и 10, можно подсчитать количество групп, в которых суммарная вероятность P_m по всем станциям превышает этот уровень. В результате такой обработки на выходе получим число случаев, когда модель уверенно регистрирует наличие сейсмического события минимум на 8 и 10 станциях, соответственно (рис. 9).

Для проверки корректности такого подхода были использованы данные, опубликованные на сайте Института сейсмологии НАН КР, на странице, посвященной Учтурфанскому землетрясению (https://seismo.kg/different/uqturpan_earthquake.php). В частности, исполь-

зовалось распределение количества афтершоков главного события по дням за период с 22 по 31 января 2024 г. (рис. 9).

Анализ графиков показывает, что в целом модель воспроизводит вариации количества афтершоков, выделенных вручную. Также видно, что при $N_s=8$, модель зарегистрировала больше сейсмических событий по сравнению с ручной обработкой. Большее количество событий, выделенное моделью для каждого дня, можно объяснить несколькими причинами. Во-первых, модель не разделяет обнаруженные события по расстоянию, поэтому в итоговом количестве присутствуют не только Учтурфанские афтершоки, но и региональные сейсмические события, зарегистрированные станциями сетей KRNET и KNET. Хотя их количество несравнимо меньше чем количество афтершоков Учтурфанского землетрясения, тем не менее они будут вносить свой малый вклад. Во-вторых, в расчет могли быть включены события, которые при ручной обработке были проигнорированы из-за их низкого энергетического класса.

При $N_s=10$, модель идентифицировала меньшее количество сейсмических событий по сравнению с ручной обработкой. Это связано с тем, что повышение порогового значения N_s снижает количество обнаруженных событий, поскольку увеличивается минимальный энергетический класс, необходимый для их регистрации (чем сильнее землетрясение, тем на большем

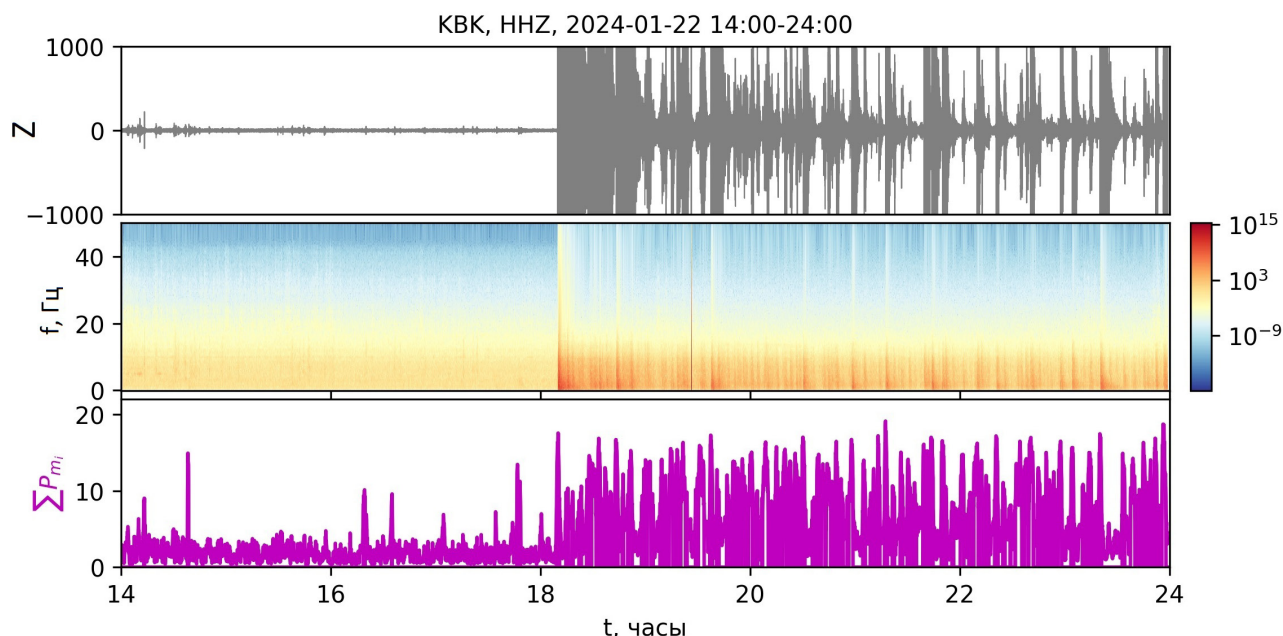


Рис. 8. Запись волновой формы (Z канал) (верхний график) и ее спектрограмма (центральный график) на станции KBK и ΣP_m по всем действующим станциям KRNET и KNET (нижний график) для периода 22-01-2024 14:00–24:00 (UTC).

Fig. 8. Waveform record (Z channel) (top graph) and its spectrogram (center graph) at station KBK and the sum of probabilities ΣP_m across all active stations in KRNET and KNET networks (bottom graph) for the period 22-01-2024, 14:00–24:00 (UTC).

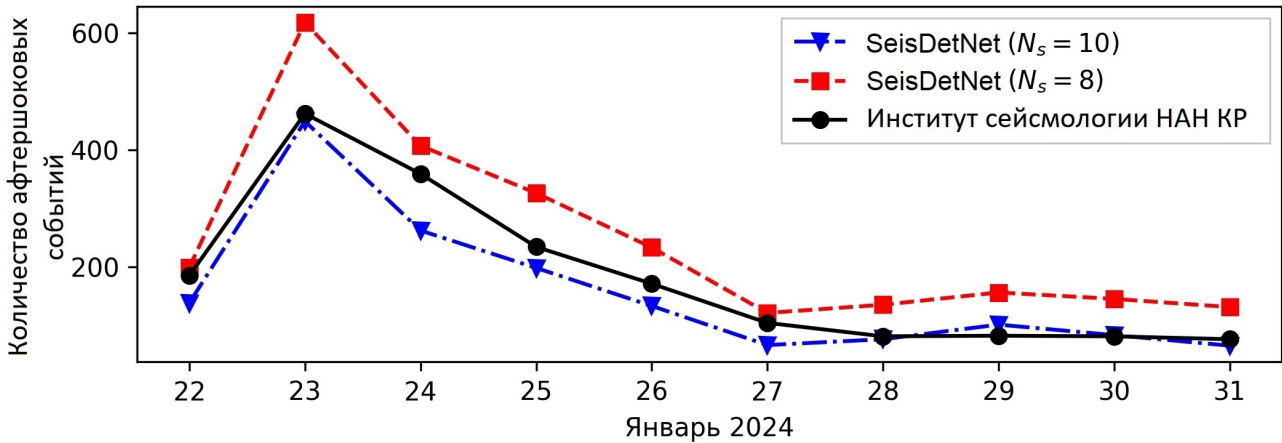


Рис. 9. Количество афтершоковых событий, выделенных вручную (по данным Института сейсмологии НАН КР) и нейронной сетью SeisDetNet (для порога минимального количества станций N_s равного 8 и 10, соответственно).

Fig. 9. Number of aftershock events identified manually (based on data of Institute of Seismology of the National Academy of Sciences of the Kyrgyz Republic) and by the SeisDetNet neural network (for the threshold of the minimum number of stations N_s equal to 8 and 10, respectively).

количестве станций оно будет уверенно зафиксировано). При этом, следует отметить, что выбор оптимального порога N_s должен осуществляться на практике в зависимости от задач обработки и количества доступных сейсмических станций.

Для точного выделения событий афтершоковой последовательности требуется дальнейшее развитие методики. В частности, полученные вырезы сейсмических событий необходимо подавать на вход другой нейронной сети для определения моментов прихода P- и S-волн, с последующим расчетом эпицентрального расстояния на основе разности времен их прихода. При этом, региональные сейсмические события, не относящиеся к Учтурфанской афтершоковой последовательности, могут быть исключены, например, с учетом известного расстояния от сейсмических станций до области афтершокового роя.

В работе (Mousavi et al., 2020) показано, что нейросетевой подход значительно повышает эффективность обработки сложных задач, таких как анализ афтершоковых последовательностей. Например, при обработке афтершоков землетрясения Тоттори ($M_w=6.6$), произошедшего в Японии в 2000 году, нейронная сеть позволила обнаружить и локализовать 21092 события, что более чем в два раза превышает количество событий, определенных вручную (8500 событий, Fukuyama et al., 2003).

ЗАКЛЮЧЕНИЕ

Проведена апробация модели SeisDetNet, предназначенной для классификации сейсмических событий и сейсмического шума по записям волновых форм. Для выделения

сейсмических событий из непрерывной записи произвольной продолжительности предложен алгоритм анализа волновой формы в скользящем окне, при котором на вход модели подаются последовательные участки длиной в 1 минуту, а на выходе формируется временной ряд вероятности (P_m) того, что анализируемый участок содержит сейсмическое событие. Участки, где значение временного ряда превышало заданный порог ($P_m \geq 0.3$), классифицировались как сейсмическое событие. Расширение алгоритма на задачу обработки данных с нескольких сейсмических станций показало хорошие результаты.

В частности, модель выявила все события из каталога KNET за период с января по февраль 2024 года, включая события малого энергетического класса ($K \leq 7$). Кроме того, результаты автоматического детектирования сейсмических событий после Учтурфанского землетрясения (22.01.2024 г., 18:09 UTC, $M_w=7$), большинство из которых являются афтершоками, сопоставимы с результатами ручной обработки и хорошо с ними согласуются. Разработанную нейронную сеть SeisDetNet можно использовать для автоматизации предварительной обработки записей волновых форм с сейсмических станций, в части предварительного выделения сейсмических событий для последующего анализа.

Кроме того, SeisDetNet может быть применена для задач идентификации микросейсмического отклика геосреды на воздействие мощными импульсами тока при активном электроразведании с помощью системы ЭРГУ-600, а также для изучения наведенной сейсмичности, например, инициированной сильными солнечными

вспышками. Дальнейшее развитие методики предполагает расширение функционала нейросетевого подхода за счет добавления дополнительного модуля для определения момента вступления Р- и S-волн, реализованного в виде отдельной нейронной сети.

Работа выполнена в рамках государственного задания Федерального государственного бюджетного учреждения науки Научной станции Российской академии наук в г. Бишкеке по теме: «Изучение геофизических полей и процессов как основы прогноза землетрясений на базе мониторинга и моделирования неупругих процессов в сейсмогенерирующих средах» (тема № 1021052806454-2-1.5.1).

Список литературы [References]

- Абдыраева Б.С., Малдыбаева М.Б., Сабирова Г.А.* Механизм очага главного толчка землетрясения 22.01.2024 г. (MPV = 6.9), Китай (КНР) // Вестник Института сейсмологии НАН КР. 2024. № 1(23). С. 8–14 [*Abdyraeva B., Maldybaeva M., Sabirova G.* The focal mechanism of the main shock of the earthquake on January 22, 2024 (MPV=6.9), China // Vestnik Instituta seysmologii NAN KR. 2024. № 1(23). P. 8–14 (in Russian)].
- Баталева Е.А., Мухаммадеева В.А.* Комплексный электромагнитный мониторинг геодинамических процессов Северного Тянь-Шаня (Бишкекский геодинамический полигон) // Геодинамика и тектонофизика. 2018. Т. 9. № 2. С. 461–487. <https://doi.org/10.5800/GT-2018-9-2-0356> [*Bataleva E.A., Mukhamadeeva V.A.* Complex electromagnetic monitoring of geodynamic processes in the Northern Tien Shan (Bishkek geodynamic test area) // Geodynamics & Tectonophysics. V. 9. № 2. P. 461–487 (in Russian)].
- Гульельми А.В., Лавров И.П., Собисевич А.Л.* Внезапные начала магнитных бурь и землетрясения // Солнечно-земная физика. 2015. Т. 1. № 1. С. 98–103. <https://doi.org/10.12737/5694> [*Guglielmi A.V., Lavrov I.P., Sobisevich A.L.* Storm sudden commencements and earthquakes // Solar-Terrestrial Physics, 2015. V. 1. № 1. P. 98–103 (in Russian)].
- Имашев С.А., Рыбин А.К.* Сейсмические и геоакустические отклики земной коры на зондирования мощными электрическими импульсами на территории Бишкекского Геодинамического Полигона // Наука и технологические разработки. 2023. Т. 102. № 2–3. С. 63–88 [*Imashev S.A., Rybin A.K.* Seismic and geoaoustic responses of the earth's crust to sensing with high energy electric pulses at the territory of the Bishkek Geodynamic Polygon // Nauka i tekhnologicheskiye razrabotki. 2023. V. 102. № 2–3. P. 63–88 (in Russian)].
- Имашев С.А., Аладьев А.В.* Обнаружение сейсмических событий на основе искусственной нейронной сети SeisDetNet. Часть 1. Архитектура нейронной сети // Вестник КРАУНЦ. Науки о Земле. 2024. № 4. Вып. 64. С. 59–70. <https://10.31431/1816-5524-2024-4-64-59-70> [*Imashev S.A., Aladev A.V.* SeisDetNet: Artificial neural network for seismic event detection. Part 1: Architecture // Vestnik KRAUNTs. Nauki o Zemle. 2024. № 4(64). P. 59–70 (in Russian)].
- Соколова И.Н., Габсатарова И.П., Березина А.В. и др.* Сильное землетрясение 22 января 2024 г. с Mw=7.0 на юге Тянь-Шаня // Российский сейсмологический журнал. 2024. Т. 6. № 1. С. 42–64. <https://doi.org/10.35540/2686-7907.2024.1.03> [*Sokolova I.N., Gabsatarova I.P., Beryozina A.V. et al.* Large earthquake on January 22, 2024 with Mw=7.0 in the south of Tien Shan // Rossiiskii seismologicheskii zhurnal. V. 6. № 1. P. 42–64 (in Russian)].
- Сычева Н.А.* Киргизская сейсмологическая сеть KNET // Вестник КРСУ. 2016. Т. 16. № 5. С. 175–183 [*Sycheva N.A.* Kyrgyz seismic network KNET // Vestnik KRSU. 2016. V. 16. № 5. P. 175–183 (in Russian)].
- Сычева Н.А.* Солнечные вспышки, сильные магнитные бури и вариации уровня сейсмического шума на территории северного Тянь-Шаня // Геофизические процессы и биосфера. 2022. Т. 21. № 4. С. 93–109. <https://doi.org/10.21455/GPB2022.4-7> [*Sycheva N.A.* Solar flares, strong magnetic storms and variations in the level of seismic noise in the northern Tien Shan // Geofizicheskiye protsessy i biosfera. 2022. V. 21. № 4. P. 93–109 (in Russian)].
- Chung J., Gulcehre C., Cho K. et al.* Empirical evaluation of gated recurrent neural networks on sequence modeling // NIPS 2014 Workshop on Deep Learning, December 2014. 2014. P. 1–9.
- Fukuyama E., Ellsworth W.L., Waldhauser F. et al.* Detailed Fault Structure of the 2000 Western Tottori, Japan, Earthquake Sequence // Bulletin of the Seismological Society of America. 2003. V. 93. № 4. P. 1468–1478. <https://doi.org/10.1785/0120020123>
- Münchmeyer J., Bindi D., Leser U. et al.* Earthquake magnitude and location estimation from real time seismic waveforms with a transformer network // Geophysical Journal International. 2021. V. 226. № 2. P. 1086–1104. <https://doi.org/10.1093/gji/ggab139>
- Münchmeyer J., Woollam J., Rietbrock A. et al.* Which Picker Fits My Data? A Quantitative Evaluation of Deep Learning Based Seismic Pickers // JGR Solid Earth. 2022. V. 127. № 1. P. e2021JB023499. <https://doi.org/10.1029/2021JB023499>
- Mousavi S.M., Ellsworth W.L., Zhu W. et al.* Earthquake transformer—an attentive deep-learning model for simultaneous earthquake detection and phase picking // Nature Communications. 2020. V. 11. № 1. P. 3952.
- Withers M., Aster R., Young C. et al.* A comparison of select trigger algorithms for automated global seismic phase and event detection // Bulletin of the Seismological Society of America. 1998. V. 88. № 1. P. 95–106. <https://doi.org/10.1785/BSSA0880010095>
- Zhu W., Beroza G.C.* PhaseNet: A Deep-Neural-Network-Based Seismic Arrival Time Picking Method // Geophysical Journal International. 2018. V. 216. № 1. P. 261–273. <https://doi.org/10.1093/gji/ggy423>
- Zhou Y., Yue H., Kong Q. et al.* Hybrid Event Detection and Phase-Picking Algorithm Using Convolutional and Recurrent Neural Networks // Seismological Research Letters. 2019. V. 90. № 3. P. 1079–1087. <https://doi.org/10.1785/0220180319>

ОБНАРУЖЕНИЕ СЕЙСМИЧЕСКИХ СОБЫТИЙ
**SEISDETNET: ARTIFICIAL NEURAL NETWORK
FOR SEISMIC EVENT DETECTION. PART 2: MODEL ASSESSMENT**

S.A. Imashev, A.V. Aladev

*Research Station of the Russian Academy of Sciences in Bishkek, Bishkek,
Kyrgyz Republic; 720049; e-mail: sanzhar.imashev@gmail.com*

Received July 19, 2024; revised March 05, 2025; accepted March 25, 2025

Based on a combination of convolutional and fully connected neural networks, we developed the SeisDetNet model to distinguish seismic events from seismic noise using waveform records. We also proposed an algorithm for detecting seismic events in continuous records of arbitrary duration. It processes waveforms in a sliding window, feeding successive 1-minute segments into SeisDetNet and producing a time series of seismic event probabilities. Extending this approach to analyze records from multiple seismic stations demonstrated promising results. Specifically, the model successfully detected all events in the KNET seismic catalog of the Research Station of the RAS for January–March 2024, including low-energy earthquakes ($K \leq 7$). Furthermore, testing the model for detecting aftershocks of the strong Uchturpan earthquake with $M_w = 7$ that occurred on January 22, 2024, at 18:09 UTC near the China-Kyrgyzstan border, showed results comparable to manual processing.

Keywords: seismic event, neural network, waveforms, aftershocks.