

ОБНАРУЖЕНИЕ СЕЙСМИЧЕСКИХ СОБЫТИЙ НА ОСНОВЕ ИСКУССТВЕННОЙ НЕЙРОННОЙ СЕТИ SeisDetNet. Часть 1. АРХИТЕКТУРА НЕЙРОННОЙ СЕТИ

© 2024 С.А. Имашев, А.В. Аладьев

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

Поступила в редакцию 19.07.2024; после доработки 10.11.2024; принята в печать 25.12.2024

Разработана искусственная нейронная сеть SeisDetNet, предназначенная для разделения сейсмических событий и сейсмического шума по записям волновых форм. В качестве источника данных для обучения, валидации и тестирования использовалась международная база данных STEAD, которая содержит минутные записи локальных землетрясений и сейсмического шума. В частности, были выбраны волновые формы с 27 сейсмических станций на территории Кыргызстана и близлежащих территорий из сетей KRNET, KNET, KZ, G и TJ, которые присутствуют в базе данных STEAD. Архитектура модели представляет собой комбинацию сверточной сети, которая предназначена для выделения ключевых признаков разделения классов и полносвязной сети для задачи классификации входной записи как сейсмическое событие или сейсмический шум. Проверка работы модели на тестовой выборке показала хорошие результаты, в частности, метрики бинарной классификации были следующими: точность (accuracy) 0.983, точность (precision) 0.989, полнота (recall) 0.982 и F1-метрика 0.985.

Ключевые слова: сейсмическое событие, нейронная сеть, обнаружение, бинарная классификация.

ВВЕДЕНИЕ

Сейсмология, как наука об изучении сейсмических явлений, сталкивается с постоянным ростом объема данных, поступающих с сейсмических станций по всему миру. Эти данные представляют собой ценный источник информации о геодинамических процессах в недрах Земли, анализ которых имеет ключевое значение для задач геофизики, в том числе, связанных с прогнозом землетрясений (Jozinović et al., 2020). Современные технологии сейсмического мониторинга позволяют собирать данные с высокой пространственной плотностью и частотой дискретизации, что представляет значительные вызовы при их анализе и интерпретации. Необходимость эффективной обработки и анализа этих данных большого объема стимулирует развитие методов искусственного интеллекта, включая применение искусственных нейронных сетей, для автоматизации процессов обработки сейсмических записей (Kong et al., 2019; Kuang et al., 2021), в частности процедуры выделения

сейсмических событий (Heck et al., 2022; Lara et al., 2021), определения моментов вступления основных фаз сейсмической волны (Li et al., 2022; Ross et al., 2018a), оценки магнитуды и эпицентрального расстояния (Münchmeyer et al., 2021; Ristea, Radoi, 2022).

Современные модели глубокого обучения, например, такие как BasicPhaseAE (Woollam et al., 2019), PhaseNet (Zhu, Beroza, 2018), EQTransformer (Mousavi et al., 2020), GPD (General Phase Detection) (Ross et al., 2018b), представляют собой комплексные системы для анализа сейсмических данных. Так как основной функционал этих моделей направлен на автоматическое выделение фаз P и S-волн, процесс классификации участка сейсмической записи, как сейсмического события проводится на основе выявленной фазы P-волны. Из указанных моделей только в EQTransformer задача детектирования сейсмического события выделена в отдельную ветку декодера на основе одномерных сверточных слоев (Mousavi et al., 2020). Однако также известно, что эти модели имеют региональные особенности, при которых

эффективность обнаружения фаз варьируется в зависимости от региона, в котором они применяются (Münchmeyer et al., 2022), так как обучение было проведено на конкретных датасетах, сформированных из данных, полученных в определенных регионах. Например, модель BasicPhaseAE обучена на данных сейсмологических сетей севера Чили, PhaseNet — северной Калифорнии, GPD — южной Калифорнии (Münchmeyer et al., 2022).

В настоящей работе рассматривается архитектура разработанной нейронной сети SeisDetNet для анализа сейсмических записей с целью их классификации, на наличие волновых форм землетрясений или сейсмического шума, а также характеристика обучающих данных, особенности их предварительной обработки, процедуры обучения и оценки качества работы нейросетевой модели. Предлагаемая модель может быть использована в комплексной системе сейсмического мониторинга в задачах предварительного выделения сейсмических событий для последующей обработки и анализа, как например, определения фаз, оценки магнитуды и эпицентрального расстояния.

ДАННЫЕ СЕЙСМИЧЕСКИХ СОБЫТИЙ

Наличие большого объема сейсмических данных и вычислительных ресурсов, вместе с разработкой передовых методик способствует созданию надежных нейросетевых моделей и алгоритмов для обработки и анализа сейсмических сигналов. При этом необходимым условием построения таких моделей является большой объем размеченных данных, прошедших проверку. В качестве таковых может служить база данных сейсмических событий STEAD (Stanford Earthquake Dataset), поддерживаемая Стэнфордским университетом (Mousavi et al., 2019). Основными ее особенностями являются: разнообразие географических регионов и большой объем примеров землетрясений (~450000), а также открытый доступ и структурированность данных, что делает базу данных STEAD, по нашему мнению, ценным ресурсом для широкого круга задач сейсмологии, в частности, при разработке новых методов анализа сейсмических данных, основанных на алгоритмах машинного обучения.

Набор данных в его текущем состоянии содержит две категории: записи локальных землетрясений (зарегистрированные в пределах 350 км от эпицентра) и записи сейсмического шума. Класс сейсмических событий содержит ~1050000 трехкомпонентных сейсмограмм (каждая длительностью в 60 секунд), связанных с ~450000 землетрясениями, произошедшими в период

с 1984 по 2018 гг. (<https://github.com/smousavi05/STEAD>). Землетрясения, входящие в базу данных были зарегистрированы 2613 сейсмометрами по всему миру, расположенными в пределах 350 км от эпицентра землетрясений. Класс сейсмических шумов содержит ~100000 записей. Все записи представлены в виде отдельных массивов NumPy (Johansson, 2018) длиной в 6000 отсчетов (60 с при дискретизации в 100 Гц), для каждой из трех ортогональных компонент (восток-запад (E), север-юг (N) и в вертикальном направлении (Z)) колебания поверхности земли, записанные в единицах отсчетов амплитуды сигнала (amplitude counts) (Mousavi et al., 2019). Необходимо отметить, что первый отсчет записи для класса сейсмического события выбран случайным образом так, чтобы он находился в пределах 5–10 с до момента вступления Р-волны.

Обучающая, валидационная и тестовая выборки. Для задач обучения, валидации и тестирования нейронной сети были выбраны сейсмические станции на территории Кыргызстана и близлежащих территорий, которые присутствуют в базе данных STEAD. А именно: 15 станций сети KR (Кыргызстан): ANVS, ARK, ARLS, ARSB, BOOM, BTK, DRK, EKS, FRU1, KDJ, NRN, OHN, PRZ, TOKL, TRKS (<http://ds.iris.edu/mda/KR>); 1 станция сети KN (Кыргызстан): AAK, которая входит в международную сеть II в системе IRIS (<http://ds.iris.edu/mda/II/AAK>); 9 станций сети KZ (Казахстан): ABKAR, AKTO, BVAR, CHKZ, KNDC, MAKZ, MKAR, OTUK, PDGK (<http://ds.iris.edu/mda/KZ>); 1 станция сети G (Китай): WUS (<http://ds.iris.edu/mda/G/WUS>); 1 станция сети TJ (Таджикистан): GARM (<http://ds.iris.edu/mda/TJ/GARM>) (рис. 1).

Так как в базе STEAD количество записей сейсмических событий и сейсмического шума отличаются на порядок, то было решено для задач обучения, валидации и тестирования нейросети выбрать 4000 сейсмических событий и 3000 примеров сейсмического шума, чтобы максимально сбалансировать выборки (рис. 2а). Необходимо отметить, что станции, входящие в сети KR и KN, а также приграничные станции KNDC, PDGK, WUS и GARM, представлены в базе STEAD сейсмическими событиями с энергетическим классом в диапазоне $K = 7-15$. В дальнейшем, выборку сейсмических событий, полученных с вышеупомянутых станций будем обозначать как «Группа Б» (рис. 2б). Для возможности нейронной сети детектировать сейсмические события малого класса ($K < 7$) было решено добавить данные, полученные с региональных сейсмических групп, а именно — с 7 станций сети KZ: ABKAR, AKTO, BVAR, CHKZ, MAKZ, MKAR, OTUK («Группа А») (568 волновых форм сейсмических событий и 684 записи сейсмического шума).

ОБНАРУЖЕНИЕ СЕЙСМИЧЕСКИХ СОБЫТИЙ

Сейсмические события, зарегистрированные на этих станциях, в базе данных STEAD характеризуются энергетическими классами в диапазоне $K = 4.5-7.5$ (рис. 2б). Глубина сейсмических событий в итоговой выборке в основном находилась в диапазоне 0–20 км (рис. 2в).

Также нужно отметить, что в процедуре обучения и валидации использовалась вся выборка (Группа А + Группа Б), тогда как на этапе тестирования использовалась выборка из ближайших

к территории Бишкекского Геодинамического Полигона (БГП) сейсмических станций с наибольшей представительностью: ARK, ARLS, KDJ, ANVS, BOOM, NRN, KNDC, AAK. 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). Объем тестовой выборки в 20 % (1400 записей)

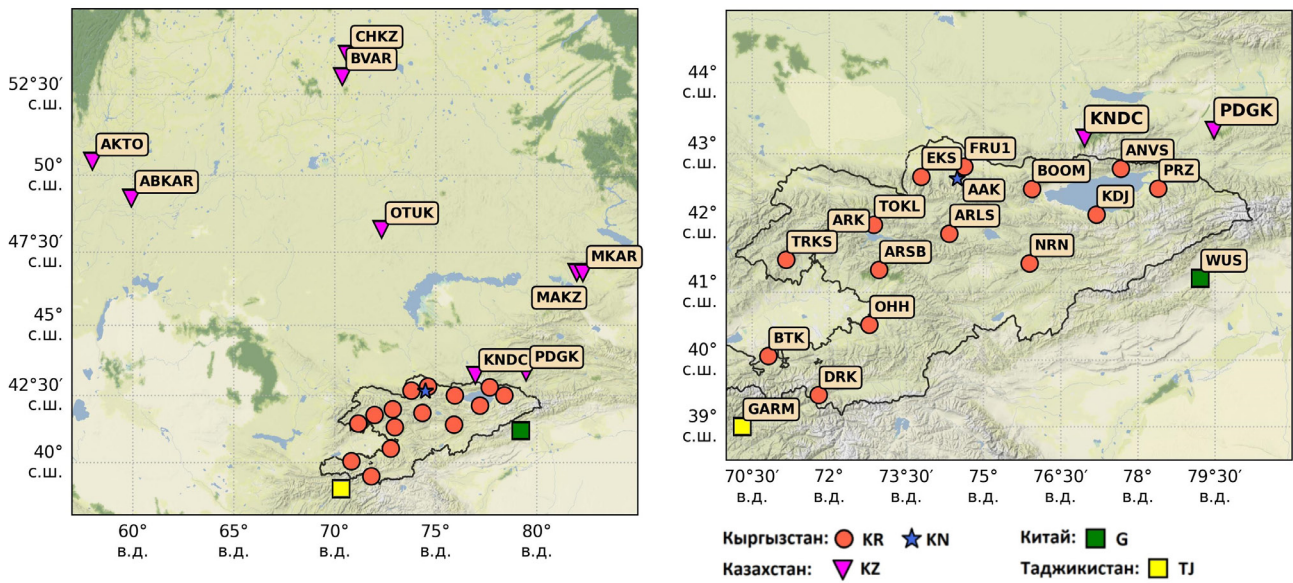


Рис. 1. Карты расположения сейсмических станций, данные которых использовались на этапах обучения, валидации и тестирования нейросети. Слева: общее расположение всех станций, справа: станции Кыргызской Республики и приграничные станции. Контуром выделена территория Кыргызской Республики. Цветом и маркерами обозначены сейсмологические сети: KR (Кыргызстан) (<http://ds.iris.edu/mda/KR>), KN (Кыргызстан) (<http://ds.iris.edu/mda/II/AAK>), KZ (Казakhstan) (<http://ds.iris.edu/mda/KZ>), G (Китай) (<http://ds.iris.edu/mda/G/WUS>) и TJ (Таджикистан) (<http://ds.iris.edu/mda/TJ/GARM>).

Fig. 1. Maps of the seismic stations whose data were used during the neural network training, validation, and testing stages. Left: overall location of all stations; right: stations in the Kyrgyz Republic and bordering stations. The outline highlights the territory of the Kyrgyz Republic. Colors and markers indicate seismological networks: KR (Kyrgyzstan) (<http://ds.iris.edu/mda/KR>), KN (Kyrgyzstan) (<http://ds.iris.edu/mda/II/AAK>), KZ (Kazakhstan) (<http://ds.iris.edu/mda/KZ>), G (China) (<http://ds.iris.edu/mda/G/WUS>), and TJ (Tajikistan) (<http://ds.iris.edu/mda/TJ/GARM>).




Рис. 2. Характеристика выборки данных для обучения, валидации и тестирования нейросети: количество примеров сейсмических событий и шума (а); гистограмма распределения энергетического класса (б) и глубин сейсмических событий (в).

Fig. 2. Characteristics of the training, validation, and test datasets: number of examples of seismic events and noise (a); histogram of the energy class distribution (b) and the depths of seismic events (v).

был отделен из общей выборки, из них 815 записей — волновые формы сейсмических событий и 585 записей — примеры сейсмического шума. Затем из оставшегося набора в 5600 записей (3185 записей землетрясений и 2415 записей шума) была отделена валидационная выборка объемом в 16 % (от общего количества записей), а оставшаяся часть (64 %) составила обучающую выборку. Объем данных для валидационной и тестовой выборок в пределах 15–20 % от общего количества является общепринятым в задачах машинного обучения. Эта пропорция предоставляет достаточно данных для проверки модели, сохраняя при этом основную часть данных для обучения (Bishop, Bishop, 2024). Во всех случаях конструирования выборок была использована процедура предварительного перемешивания (shuffling) с последующей выборкой необходимого объема. Итоговая характеристика выборок приведена в таблице.

МЕТОДИКА

В качестве входных данных были использованы записи трех компонент сейсмического события или шума после процедур предварительной обработки и подготовки данных для сверточного слоя.

Предобработка и подготовка данных. В качестве входных данных для нейронной сети было решено использовать не исходные записи, а их

спектрограммы (отдельно для каждого из каналов E, N, Z — восточная, северная и вертикальная компоненты). Использование спектрограмм дает возможность выделить ключевые признаки сейсмического события, которые позволяют отличить его от сейсмического шума, так как используется комбинированная информация, как в частотно-временной области, так и по значению амплитуд (рис. 3). Так, например, сейсмический шум будет характеризоваться широким спектром частот, которые присутствуют в сигнале на протяжении всей записи, а также низкими значениями амплитуд (рис. 3, слева), тогда как сейсмическое событие будет выделяться большей амплитудой, меньшим диапазоном частот, которые локализованы во времени (рис. 3, справа).

Характеристика обучающей, валидационной и тестовой выборок

Characteristics of training, validation and test datasets

	Обучающая выборка	Валидационная выборка	Тестовая выборка
Доля от общего объема, %	64%	16%	20%
Количество записей каждого класса (шум/сейсмическое событие)	1932/2548	483/637	585/815

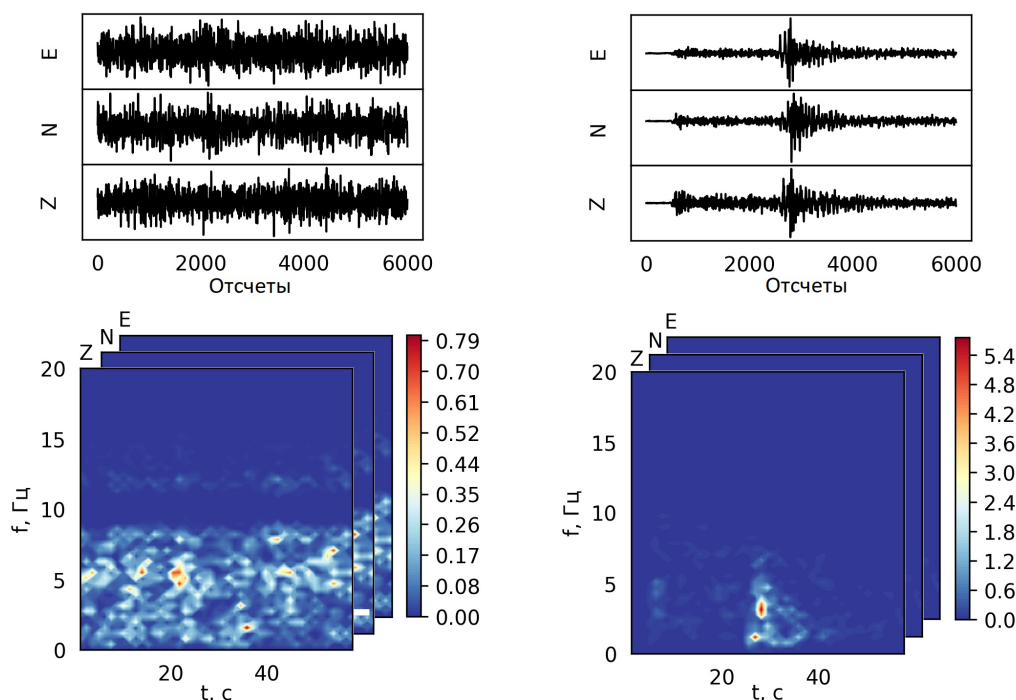


Рис. 3. Пример записей сейсмического шума (слева) и сейсмического события (справа) и их спектрограммы. E, N и Z — три ортогональные компоненты (восточная, северная и вертикальная) сейсмического сигнала в виде отсчетов амплитуды.

Fig. 3. Example of seismic noise (left) and seismic event (right) recordings, and their spectrograms. E, N and Z — three orthogonal components (eastern, northern, and vertical) of seismic signal represented as amplitude counts.

При этом, представление сейсмической записи в виде спектрограмм, в форме трехслойной двумерной матрицы (три слоя для каждого из каналов E, N, Z) будет являться аналогом цветного изображения (двумерная матрица для каждого из трех каналов R, G, B). Исходя из этого логично использовать архитектуру нейронной сети, предназначенную для анализа изображений и выделения ключевых признаков для задачи классификации. В качестве таковой архитектуры широко используются сверточные нейронные сети (Li et al., 2015).

Также необходимо отметить, что сейсмические записи подвергались процедуре нормализации, в частности, была использована стандартная нормализация данных (z-нормализация или центрирование с масштабированием), которая заключается в преобразовании данных таким образом, чтобы они имели среднее значение, равное 0 и стандартное отклонение, равное 1.

Подача данных в нормализованном виде в нейронные сети имеет ряд преимуществ и помогает улучшить процесс обучения и эффективность модели, в частности: позволяет стабилизировать и ускорить процесс обучения, способствует борьбе с проблемой затухания градиентов (gradient vanishing problem), а также улучшает обобщающую способность модели (Bishop, Bishop, 2024).

Архитектура нейронной сети. Предлагаемая архитектура является комбинацией сверточной сети, которая предназначена для выделения ключевых признаков разделения классов и полносвязной сети для задачи классификации входной записи как сейсмическое событие или сейсмический шум (рис. 4). Общее количество обучаемых параметров модели составило 30881, что

делает нейронную сеть достаточно легковесной. При разработке архитектуры сети и ее проверке учитывались правила, что минимальное количество нейронов, при котором достигаются хорошие результаты, считается более оптимальным с точки зрения простоты, скорости и обобщающей способности нейронной сети. Важно отметить при этом то, что количество нейронов должно быть адаптировано к специфике задачи, чтобы избежать переобучения. Кроме того, поскольку обучение модели проводилось с использованием графических процессоров (GPU), количество нейронов и сверточных фильтров выбиралось кратным степени двойки. Это связано с тем, что современные GPU оптимизированы для работы с данными такого формата, что повышает общую производительность модели.

Сверточные нейронные сети являются многослойными нейронными сетями прямого распространения, которые были специально разработаны для обработки многомерных массивов данных (LeCun et al., 1998). Каждый сверточный слой содержит набор линейных фильтров, называемых также ядрами для извлечения локальных признаков из частей предыдущего слоя (Ciresan et al., 2012) и передает полученные результаты свертки через нелинейный блок активации. Наша сеть содержит три последовательных сверточных слоя, выходом которых являются новые трехмерные карты признаков (feature map), количество которых удваивается с каждым последующим слоем — 8, 16 и 32.

После свертки каждый результат проходит через нелинейную функцию активации для добавления нелинейности в модель, что позволяет нейронной сети моделировать более сложные зависимости между входными данными.

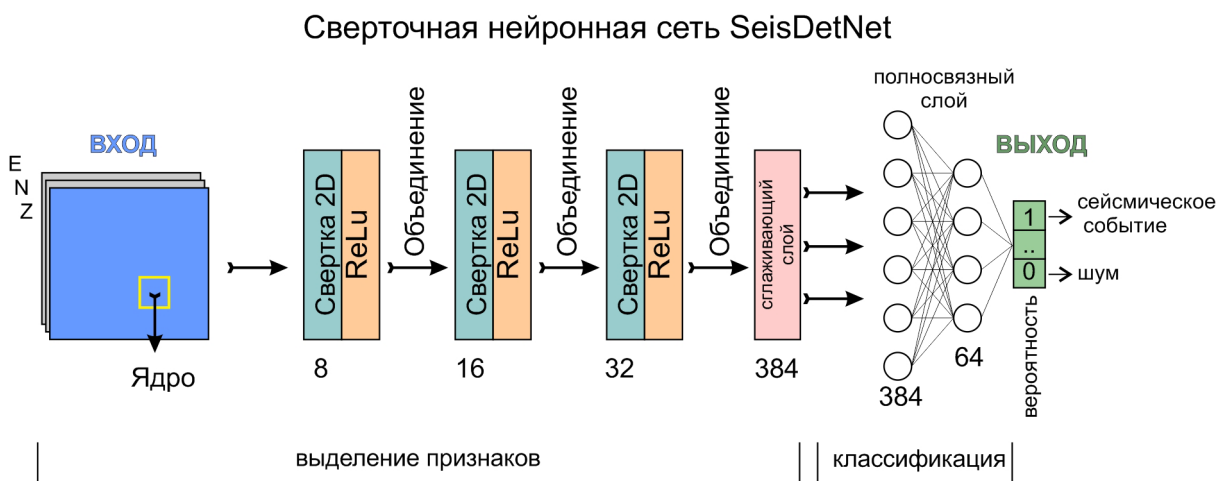


Рис. 4. Архитектура сверточной нейронной сети SeisDetNet. E, N и Z — спектрограммы восточной, северной и вертикальной компоненты сейсмического сигнала.

Fig. 4. Architecture of SeisDetNet convolutional neural network. E, N and Z represent spectrograms of east, north and vertical components of seismic signal.

В качестве функций активации была выбрана ректификационная функция ReLU (rectified linear unit) (рис. 5), основная цель которой состоит в том, что она выпрямляет отрицательные значения входа, делая их равными нулю, в то время как положительные значения оставляет без изменений (Nair, Hinton, 2010). Было установлено, что сверточные нейронные сети обучаются намного быстрее при использовании ReLU в качестве функции активации (Glorot et al., 2011). Это является следствием ее основных преимуществ: достаточно простая ее реализация ведет к более быстрым вычислениям, что напрямую ускоряет процесс обучения нейронной сети; ее форма помогает избежать проблемы затухающих градиентов, которая может возникнуть при использовании таких функций активации, как сигмоида или гиперболический тангенс и использование ReLU способствует появлению разреженных активаций, когда часть нейронов выдает нулевой результат на выходе, что увеличивает обобщающую способность модели и уменьшает вероятность переобучения.

Зачастую процедура пространственного уменьшения результата активации осуществляется путем объединения схожих локальных признаков в один (LeCun et al., 2015). Эта операция объединения, также известная как пулинг (pooling), может значительно сократить количество обучаемых параметров, тем самым улучшая производительность сети и предотвращая переобучение (Krizhevsky et al., 2012). В качестве агрегирующей функции объединяющего слоя был использован расчет максимального значения. Такое объединение путем отбора максимального значения (max pooling) является наиболее широко используемой процедурой, при которой вычисляется максимальное значение активаций

в неперекрывающихся локальных окрестностях в выходной карте признаков (Cireřan et al., 2012), что повышает инвариантность к малым пространственным смещениям (LeCun et al., 1989).

Далее карты признаков, полученные после последовательности сверточных слоев, блоков нелинейной активации с функцией ReLU и слоев объединения, соединяются и вытягиваются в одномерный вектор (размером 384) для передачи на полносвязный слой (fully connected layer), который представляет собой отдельный блок в архитектуре сети, в котором каждый нейрон входного слоя полностью связан с каждым нейроном выходного слоя. Такая полносвязная подсеть в нашей модели содержит всего три слоя: входной, соответствующий выходу со сглаживающего слоя, скрытый и выходной (рис. 4). Выход последнего полносвязного слоя подается на сигмоидную функцию активации (рис. 5), которая выдает вероятность того, что входная запись является сейсмическим событием ($P_m=1$). В случае сейсмического шума на входе, выход с модели будет близок к нулю ($P_m=0$). Однако для сейсмических событий малой амплитуды, которые могут слабо выделяться на фоне шума, модель может выдавать значения в середине диапазона 0–1. Это происходит потому, что в таких случаях модель не уверена в однозначной классификации, что приводит к промежуточным значениям вероятности. Этот эффект является предпочтительным в случае, когда нейронная сеть будет применяться в задачах по изучению 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).




Рис. 5. Функции активации, используемые в нейронной сети: ReLU (слева) и сигмоида (справа).

Fig. 5. Activation functions used in the neural network: ReLU (left) and sigmoid (right).

Обучение модели. Обучение нейронной сети происходит в результате итерационного изменения значений ее параметров. При этом основной целью такого подбора параметров является достижение малости отклонения между расчетным значением на выходе нейронной сети, определяющим вероятность того, что рассматриваемая запись является сейсмическим событием и фактическим значением метки записи из обучающего набора. Это отклонение может быть рассчитано с помощью специальных функций, называемых функциями потерь (loss function). Для задачи бинарной классификации, когда выход с модели интерпретируется в качестве вероятности появления экземпляра одного из двух классов, используется функция бинарной кросс-энтропии (Mehta et al., 2024).

Отдельно необходимо отметить важность валидационной выборки в машинном обучении, в особенности, в случае нейронных сетей глубокого обучения. Основной целью включения валидационной выборки в процесс обучения является оценка производительности модели во время обучения и оптимальный подбор гиперпараметров (параметров, которые настраиваются вручную перед началом процесса обучения и определяют структуру или способ обучения модели) (Bishop, Bishop, 2024). Также оценка работы модели на валидационной выборке позволяет отслеживать переобучение модели. Так, например, если качество работы нейросети на валидационной выборке начинает ухудшаться после достижения лучших результатов на обучающей выборке, то это может сигнализировать о начале переобучения. Эта особенность была использована для получения оптимальной модели, путем сохранения ее состояния, которое соответствовало итерации с минимальным значением функции потерь для валидационной

выборки. Также, некоторые гиперпараметры, такие как скорость обучения (learning rate), количество пакетов обучения (батчей) и эпох (epochs), а также алгоритм оптимизатора, были адаптированы на основе производительности модели на валидационной выборке. Батч представляет собой небольшую подвыборку из полного обучающего набора, которая используется для одного шага обновления параметров модели в процессе обучения. Малые размеры батча улучшают обобщающую способность модели за счет регуляризации и требуют меньших вычислительных ресурсов (Bishop, Bishop, 2024). Эпоха же представляет собой один полный проход через весь обучающий набор данных, иными словами, в процессе одной эпохи модель обучается на всех примерах из обучающей выборки. Финальные значения основных гиперпараметров были следующими: скорость обучения — 10^{-6} , количество батчей — 8 и количество эпох обучения — 1300.

В качестве оптимизационного алгоритма, отвечающего за обновление параметров модели в процессе обучения, с целью минимизации функции потерь был выбран Adam (Adaptive Moment Estimation) (Kingma, 2015). Использование алгоритма Adam позволяет в большинстве случаев избежать тщательной настройки скорости обучения за счет того, что алгоритм автоматически адаптирует ее для каждого обучаемого параметра на основе истории градиентов. Как уже упоминалось, в течение процесса обучения запоминалось минимальное значение функции потерь для валидационной выборки и состояние модели в эту эпоху, чтобы в дальнейшем использовать ее в качестве рабочей версии (рис. 6). Глобальный минимум функции потерь для валидационной выборки был достигнут на 915 эпохе, после которой нейронная сеть стала переобучаться (рис. 6, слева), т.е. модель становится сильно




Рис. 6. Кривые обучения: функции потерь (слева) и точности бинарной классификации (справа).

Fig. 6. Learning curves: loss function (left) and binary classification accuracy (right).

адаптированной к данным обучающей выборки, и наблюдается резкое ухудшение распознавания примеров из валидационной выборки.

Также, в качестве метрики оценки классификатора использовалась точность бинарной классификации (binary accuracy), которая отражает количество корректных предсказаний относительно всех значений, иными словами — долю правильных ответов. Учитывая, что на выходе модели получается число в диапазоне 0–1, все значения меньше 0.5 относились к классу сейсмических шумов (метка 0), а значения ≥ 0.5 — к классу сейсмических событий (метка 1). Значения точности классификации на 915 эпохе составили 98.5 % для обучающей выборки и 98.1 % для валидационной, что можно характеризовать как хороший результат обучения нейросети.

РЕЗУЛЬТАТЫ И ОБСУЖДЕНИЕ

Для задачи тестирования была использована тестовая выборка, которую модель никогда не видела в процессе обучения.

Значение, выдаваемое моделью переводилось в метки класса, по правилу, которое использовалось в случае расчета точности бинарной классификации, т.е. 0 в случае, когда выходное

значение < 0.5 и 1 когда это значение ≥ 0.5 (рис. 7). Для оценки качества бинарной классификации для тестовой выборки использовалась так называемая матрица несоответствий или ошибок (confusion matrix) (Bishop, Bishop, 2024) (рис. 8). Для описания комбинаций, которые могут получаться при сопоставлении ответов модели и истинных меток записей в матрице ошибок, используются следующие понятия:

– TP — истинно-положительные объекты (True Positive) — запись представляет собой сейсмическое событие и модель идентифицирует ее также;

– FP — ложноположительные объекты (False Positive) — запись представляет собой сейсмический шум, а модель ошибочно идентифицирует ее как сейсмическое событие;

– TN — истинно-отрицательные объекты (True Negative) — запись представляет собой сейсмический шум и модель идентифицирует ее также;

– FN — ложноотрицательные объекты (False Negative) — запись представляет собой сейсмическое событие, а модель ошибочно идентифицирует ее как сейсмический шум.

Для оценки качества работы классификатора применяются различные метрики, часть

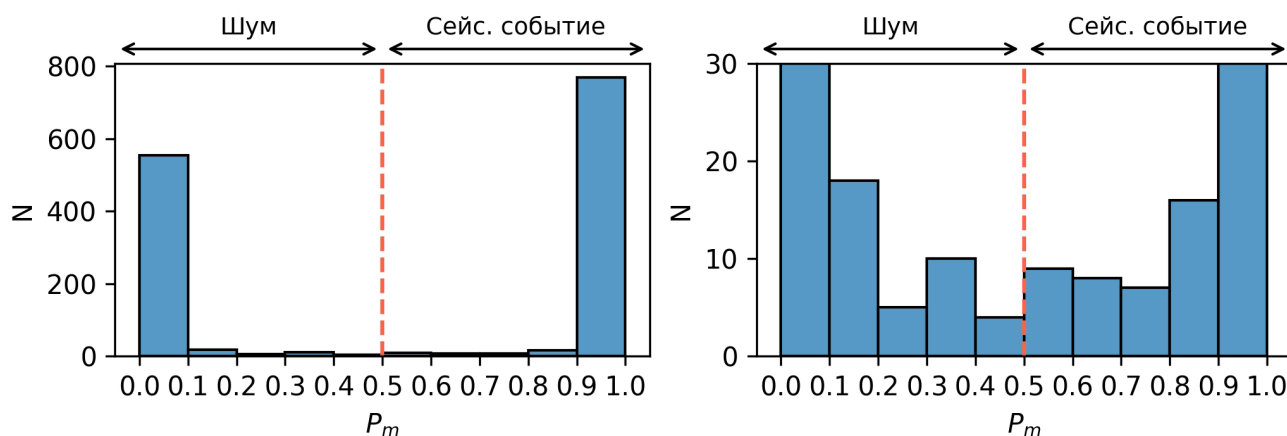


Рис. 7. Гистограмма распределения выходных значений модели P_m для тестовой выборки: слева — обычный масштаб, справа — увеличенный. Вертикальная линия — граница раздела классов.

Fig. 7. Histogram of the model output values P_m for the test set: left — regular scale, right — magnified scale. Vertical line indicates the boundary for class separation.

Рис. 8. Матрица ошибок бинарного классификатора для тестовой выборки. TP — истинно-положительные объекты, FP — ложноположительные объекты, TN — истинно-отрицательные объекты, FN — ложноотрицательные объекты.

Fig. 8. Confusion matrix of the binary classifier for the test set. TP — true positive objects, FP — false positive objects, TN — true negative objects, FN — false negative objects.

Истинные значения	Шум	TN = 576	FP = 9
	Сейсмическое событие	FN = 15	TP = 800
		Шум	Сейсмическое событие
		Модель	

которых основана на применении отношений комбинаций элементов матрицы ошибок (Bishop, Bishop, 2024). В частности, широко используются следующие метрики: *Accuracy* (точность — доля правильных случаев классификации), *Precision* (точность — доля верно классифицированных объектов среди всех объектов, которые к этому классу отнес классификатор, т.е. доля настоящих сейсмических событий среди всех записей, которые модель отнесла к сейсмическим событиям), *Recall* (полнота — отношение верно классифицированных объектов класса к общему числу элементов этого класса, т.е. доля верно идентифицированных сейсмических событий, среди всех записей с сейсмическими событиями) и *F1-score* (F1-мера — среднее гармоническое между *Precision* и *Recall*), которые вычисляются по следующим формулам:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

$$F1 = 2 * \frac{Precision * Recall}{Precision + Recall} \quad (4)$$

Для тестовой выборки метрики бинарной классификации имеют следующие значения: *Accuracy* = 0.983, *Precision* = 0.989, *Recall* = 0.982 и *F1* = 0.985, что можно считать хорошим результатом.

Несмотря на то, что метрики показывают хорошие результаты, немаловажным является узнать характеристики тех записей, на которых модель ошиблась (рис. 9).

Необходимо отметить, что в случае ложноположительных срабатываний, модель выдавала на

выходе низкое значение (~0.3) в случае дальних землетрясений, когда в анализируемой записи доминировала кода Р-волны (рис. 9, справа), т.е. модель видела больше шума, чем всплеска амплитуд. При детальном изучении 15 ложноположительных записей (сейсмические события, ошибочно классифицированные как шум), было выявлено, что 10 из них имеют значение $P_m > 0.3$. Учитывая это, и сдвигая границу раздела классов с 0.5 до 0.3, будем иметь количество ложноположительных случаев $FN=5$ (вместо 15) и $FP=13$ (вместо 9), что привело к незначительному увеличению значения метрики *F1* с 0.985 до 0.989. Из этого следует, что для различных задач, эту границу раздела классов необходимо устанавливать исходя из специфики задач: идентификация максимально возможного количества сейсмических событий, либо детектирование записей с сейсмическим шумом.

Далее была проведена проверка работы модели на данных большего размера (в ~28 раз больше тестовой выборки). Для этого из общего набора данных STEAD было выбрано по 20000 записей сейсмических событий и сейсмического шума из соседних сейсмологических сетей, в частности Казахстана (KZ), Таджикистана (TJ), Узбекистана (UZ) и Китая (IC, CB) (рис. 10). 97 % данных из этой выборки не участвовали в процессе обучения.

Для этого набора данных метрики качества классификации были равны: *Accuracy*=0.91, *Precision*=0.96, *Recall*=0.85 и *F1*=0.90. Эти результаты можно интерпретировать, как следствие того, что модель не смогла адекватно распознать некоторые сейсмические события, которые были либо малого энергетического класса, либо произошли на большом расстоянии (~300 км) (рис. 9,

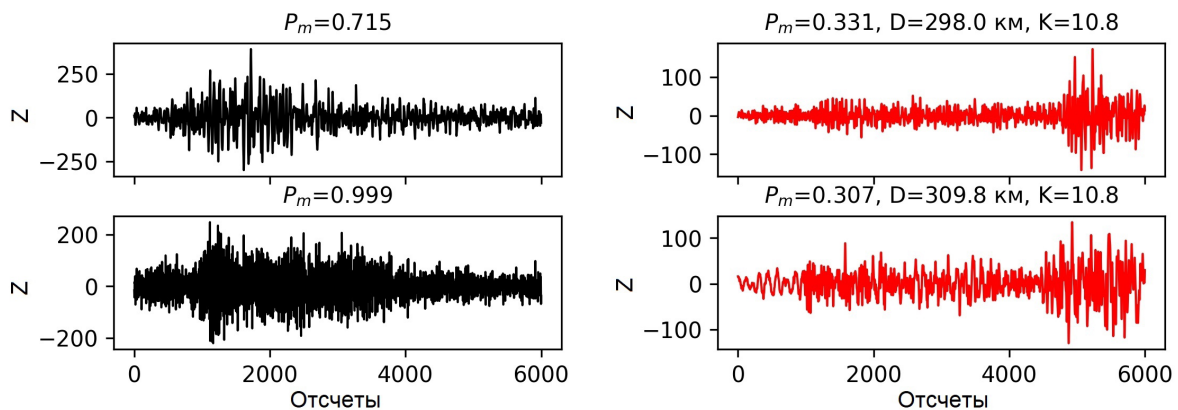


Рис. 9. Примеры ложноположительных и ложноположительных записей (при использовании значения 0.5 в качестве границы раздела классов): слева — шумы, классифицированные нейросетью как сейсмические события, справа — сейсмические события, классифицированные нейросетью как шумы. Z — вертикальная компонента сейсмического сигнала (амплитудные отсчеты), P_m — значение на выходе модели, D — расстояние до эпицентра (км), K — энергетический класс.

Fig. 9. Examples of false positive and false negative recordings (using a threshold value of 0.5 for class separation): left — noise classified as seismic events, right — seismic events classified as noise. Z — vertical component of the seismic signal (amplitude counts), P_m — model output value, D — distance to the epicenter (km), K — energy class.

Истинные значения	Шум	TN = 19243	FP=757
	Сейсмическое событие	FN=3005	TP=16995
		Шум	Сейсмическое событие
		Модель	

Рис. 10. Матрица ошибок бинарного классификатора для тестовой выборки из сейсмических станций за пределами исследуемой территории (Кыргызстан и близлежащие регионы). TP — истинно-положительные объекты, FP — ложноположительные объекты, TN — истинно-отрицательные объекты, FN — ложноотрицательные объекты.

Fig. 10. Confusion matrix of the binary classifier for the test set from seismic stations outside the investigated area (Kyrgyzstan and neighboring regions). TP — true positive objects, FP — false positive objects, TN — true negative objects, FN — false negative objects.

справа). Также записи с сейсмическим шумом с определенной низкочастотной составляющей (трендом), примеры которых модель не видела в процессе обучения, будут выдавать ложные срабатывания. В случае, когда выходное значение с модели будем соотносить с границей раздела не 0.5, а 0.3 (как в случае с тестовым набором с локальных станций), т.е. 0 в случае, когда выходное значение <0.3 и 1 когда это значение ≥ 0.3 , то значение показателя *FI* увеличивается до 0.92, а значение *Recall* до 0.91, что говорит о том, что модель недооценивает (занижает) вероятности для некоторых событий. Несмотря на это, можно сказать, что модель довольно эффективно детектирует записи сейсмических событий и шума, даже для данных на которых она не обучалась в широком диапазоне энергетических классов сейсмических событий и видов сейсмического шума. Однако, будет целесообразнее стараться использовать модель для территории, откуда были взяты обучающие примеры.

ЗАКЛЮЧЕНИЕ

На основе комбинации сверточной и полносвязной нейронных сетей была разработана нейросетевая модель SeisDetNet, предназначенная для детектирование сейсмических событий. В качестве источника обучающей, валидационной и тестовой выборок была использована база

данных STEAD Стэнфордского университета. В этой базе данных были выбраны записи волновых форм с сейсмических станций на территории Кыргызстана и сопредельных территорий из сетей KR, KN, KZ, G и TJ. Основной частью SeisDetNet является сверточная нейронная сеть, предназначенная для выделения ключевых признаков разделения классов, в то время как вспомогательная часть — это полносвязная нейросеть, которая на основе выделенных признаков классифицирует входную запись как сейсмическое событие ($P_m=1$) или сейсмический шум ($P_m=0$). Проверка работы нейронной сети на тестовой выборке показала хорошие результаты: метрики бинарной классификации имели следующие значения: *Accuracy*=0.983, *Precision*=0.989, *Recall*=0.982 и *F1-score* 0.985. Модель немного занижает значения вероятностей P_m для сейсмических событий, которые были зарегистрированы на расстояниях ~300 км и выше, что требует корректировки значения границы разделения классов, равного 0.3 вместо классического значения для задач бинарной классификации, равного 0.5. Предлагаемая архитектура нейронной сети может быть использована для предварительного выделения сейсмических событий из записей волновых формы произвольной продолжительности для последующей обработки с использованием нейросетевого подхода, в частности, пикирования фаз сейсмических волн, оценку магнитуды и эпицентрального расстояния.

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]

- Баталева Е.А., Мухамадеева В.А. Комплексный электромагнитный мониторинг геодинамических процессов Северного Тянь-Шаня (Бишкекский геодинамический полигон) // Геодинамика и тектонофизика. 2018. Т. 9. № 2. С. 461–487 [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. <https://doi.org/10.12737/5694> (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 // Naukaitekhnologicheskierazrabotki. 2023. V. 102. № 2–3. P. 63–88 (in Russian)].
- Сычева Н.* 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 // Geofizicheskiyeprotsessyibiosfera. 2022. V. 21. № 4. P. 93–109. <https://doi.org/10.21455/GPB2022.4-7> (in Russian)].
- Bishop C.M., Bishop H.* Deep Learning: Foundations and Concepts. Cham: Springer International Publishing, 2024. 649 p. <https://doi.org/10.1007/978-3-031-45468-4>
- Cireşan D., Meier U., Masci J. et al.* Multi-column deep neural network for traffic sign classification // Neural Networks. 2012. V. 32. P. 333–338. <https://doi.org/10.1016/j.neunet.2012.02.023>
- Glorot X., Bordes A., Bengio Y.* Deep Sparse Rectifier Neural Networks // Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistics. Fort Lauderdale, FL, USA. 2011. V. 15. P. 315–323.
- Heck S.L., Young C.J., Brogan R.* Comparing Traditional and Deep Learning Signal Features for Event Detection in the Utah Region // Bulletin of the Seismological Society of America. 2022. V. 112, № 5. P. 2344–2363. <https://doi.org/10.1785/0120210275>
- Johansson R.* Numerical Python: Scientific Computing and Data Science Applications with Numpy, SciPy and Matplotlib. Berkeley, CA: Apress, 2018. 700 p. <https://doi.org/10.1007/978-1-4842-4246-9>
- Jozinović D., Lomax A., Štajduhar I. et al.* Rapid prediction of earthquake ground shaking intensity using raw waveform data and a convolutional neural network // Geophysical Journal International. 2020. V. 222, № 2. P. 1379–1389. <https://doi.org/10.1093/gji/ggaa233>
- Kingma D., Ba J.* Adam: A Method for Stochastic Optimization // International Conference on Learning Representations (ICLR). San Diego, USA, 2015. P. 13.
- Kong Q., Trugman D.T., Ross Z.E. et al.* Machine Learning in Seismology: Turning Data into Insights // Seismological Research Letters. 2019. V. 90. № 1. P. 3–14. <https://doi.org/10.1785/0220180259>
- Krizhevsky A., Sutskever I., Hinton G.E.* ImageNet Classification with Deep Convolutional Neural Networks // Advances in Neural Information Processing Systems. 2012. V. 25. P. 1097–1105
- Kuang W., Yuan C., Zhang J.* Real-time determination of earthquake focal mechanism via deep learning // Nature Communications. 2021. V. 12. № 1. P. 1432. <https://doi.org/10.1038/s41467-021-21670-x>
- Lara F., Lara-Cueva R., Larco J.C. et al.* A deep learning approach for automatic recognition of seismo-volcanic events at the Cotopaxi volcano // Journal of Volcanology and Geothermal Research. 2021. V. 409. 107142. <https://doi.org/10.1016/j.jvolgeores.2020.107142>
- LeCun Y., Boser B., Denker J. et al.* Handwritten Digit Recognition with a Back-Propagation Network // Advances in Neural Information Processing Systems, 1989. V. 2. P. 396–404.
- Lecun Y., Bottou L., Bengio Y. et al.* Gradient-based learning applied to document recognition // Proceedings of the IEEE. 1998. V. 86, № 11. P. 2278–2324. <https://doi.org/10.1109/5.726791>
- LeCun Y., Bengio Y., Hinton G.* Deep learning // Nature. 2015. V. 521, № 7553. P. 436–444. <https://doi.org/10.1038/nature14539>
- Li S., Liu Z.-Q., Chan A.B.* Heterogeneous Multi-task Learning for Human Pose Estimation with Deep Convolutional Neural Network // International Journal of Computer Vision. 2015. V. 113, № 1. P. 19–36. <https://doi.org/10.1007/s11263-014-0767-8>
- Li W., Chakraborty M., Sha Y. et al.* A study on small magnitude seismic phase identification using 1D deep residual neural network // Artificial Intelligence in Geosciences. 2022. V. 3. P. 115–122. <https://doi.org/10.1016/j.aiig.2022.10.002>
- Mehta V., Kumar A., Nahar K. et al.* Binary Image Classification Using Machine Learning and Deep Quantum Neural Networks // 2024 14th International Conference on Cloud Computing, Data Science & Engineering (Confluence). 2024. P. 811–816. <https://doi.org/10.1109/Confluence60223.2024.10463226>
- Mousavi S.M., Sheng Y., Zhu W. et al.* STanfordEarthquake Dataset (STEAD): A Global Data Set of Seismic Signals for AI // IEEE Access. 2019. V. 7. P. 179464–179476. <https://doi.org/10.1109/ACCESS.2019.2947848>
- 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.
- 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>
- Nair V., Hinton G.E.* Rectified linear units improve restricted Boltzmann machines // Proceedings of the 27th International Conference on International Conference on Machine Learning. Madison, USA: Omnipress, 2010. P. 807–814.
- Ristea N.-C., Radoi A.* Complex Neural Networks for Estimating Epicentral Distance, Depth, and Magnitude of Seismic Waves // IEEE Geosci. Remote Sensing Letters. 2022. V. 19. P. 1–5. <https://doi.org/10.1109/LGRS.2021.3059422>
- Ross Z.E., Meier M., Hauksson E.* P Wave arrival picking and first-motion polarity determination with deep learning // Journal of Geophysical Research: Solid

- Earth. 2018a. V. 123, № 6. P. 5120–5129. <https://doi.org/10.1029/2017JB015251>
- Ross Z.E., Meier M., Hauksson E. et al. Generalized Seismic Phase Detection with Deep Learning // Bulletin of the Seismological Society of America. 2018b. V. 108, № 5A. P. 2894–2901. <https://doi.org/10.1785/0120180080>
- Woollam J., Rietbrock A., Bueno A. et al. Convolutional Neural Network for Seismic Phase Classification, Performance Demonstration over a Local Seismic Network // Seismological Research Letters. 2019. V. 90, № 2A. P. 491–502. <https://doi.org/10.1785/0220180312>
- 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>

SeisDetNet: ARTIFICIAL NEURAL NETWORK FOR SEISMIC EVENT DETECTION. Part 1: ARCHITECTURE

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 07, 2024; revised November, 10, 2024; accepted December 25, 2024

An artificial neural network, SeisDetNet, has been developed for distinguishing seismic events from seismic noise based on waveform records. The international STEAD database, which contains minute-long records of local earthquakes and seismic noise, was used as the data source for training, validation, and testing. Specifically, we selected waveforms from 27 seismic stations located in Kyrgyzstan and surrounding areas from the KRNET, KNET, KZ, G, and TJ networks, present in the STEAD database. The model architecture is a combination of a convolutional network, designed to extract key features for class separation, and a fully connected network for the task of classifying the input record as either a seismic event or seismic noise. Evaluating the model on the test set showed good results, with the following binary classification metrics: accuracy of 0.983, precision of 0.989, recall of 0.982, and F1-score of 0.985.

Keywords: seismic event, neural network, detection, binary classification.