

DOI: <https://doi.org/10.30898/1684-1719.2026.7.8>

УДК: 550.34.01

ПОВЫШЕНИЕ ПОМЕХОУСТОЙЧИВОСТИ ДЕТЕКТИРОВАНИЯ МИКРОСЕЙСМИЧЕСКИХ СОБЫТИЙ НА ДАННЫХ DAS НА ОСНОВЕ ГИБРИДНОГО ПОДХОДА MLE И МОДЕЛИ U-NET

Б.В. Емельянов ¹, О.Н. Шерстюков ¹, В.А. Рыжов ²

¹ Казанский (Приволжский) федеральный университет,
420008, Казань, ул. Кремлевская, д. 18

² ООО «Призмагео», 42003, Казань, ул. Серова, д. 51/11

Статья поступила в редакцию 4 июня 2026 г.

Аннотация. Работа посвящена разработке автоматизированного метода детектирования и пространственной локализации микросейсмических событий по скважинным данным распределенного акустического зондирования. Цель исследования состоит в повышении устойчивости обнаружения слабых событий в условиях интенсивных нестационарных и пространственно-коррелируемых помех. Методическая основа включает формирование базы синтетических микросейсмических сигналов с варьируемыми параметрами источника и уровнем сигнал-шум с их последующей интеграцией в реальные шумовые записи для имитации полевых условий. Первичная оценка пространственно-временных параметров источника выполняется методом максимального правдоподобия с построением трехмерных массивов, описывающих распределение значений решающей функции в координатах глубина-радиус-время. На основе этих массивов разработана и обучена нейросетевая модель типа кодировщик-декодировщик, предназначенная для уточнения координат события и подавления влияния сложной структуры шума. Обучение и тестирование выполнены на обучающей, валидационной и независимой тестовой выборках с

использованием регрессионных и классификационных метрик качества. Полученные результаты демонстрируют снижение среднего абсолютного и квадратичного отклонений координат локализации, а также рост согласованности классификации по сравнению с применением только пороговой обработки функции правдоподобия. Показано, что предложенный гибридный подход обеспечивает повышение вероятности обнаружения слабых микросейсмических событий при одновременном сокращении числа ложных срабатываний в условиях реальных скважинных шумов.

Ключевые слова: DAS, микросейсмический мониторинг, MLE, U-Net.

Автор для переписки: Емельянов Булат Владимирович, emelyanov.bulat.91@mail.ru

Введение

Технология распределенного акустического зондирования (Distributed Acoustic Sensing, DAS) в последние годы стала одним из наиболее перспективных инструментов мониторинга микросейсмической активности в скважинных условиях. Использование стандартного оптоволоконного кабеля в качестве линейной антенны датчиков позволяет получать непрерывные записи вибраций с пространственным шагом порядка 1 м и частотой дискретизации до 10 кГц, что формирует массивы данных высокой размерности и плотности наблюдения [1-3]. Благодаря этим свойствам технология DAS начинает активно применяться в задачах контроля прорыва покрышки при образовании трещин авто ГРП в нагнетательных скважинах, мониторинга межпластовых перетоков и геомеханических процессов, а также для мониторинга режима работы скважин и контроля целостности их конструкции [4-6].

Однако высокая пространственная плотность измерений и большой объем регистрируемых данных сопровождаются существенными методическими трудностями. В скважинных условиях сигналы микросейсмических событий часто маскируются интенсивными техногенными помехами, обладающими выраженной нестационарностью и пространственной коррелированностью [7,8]. К таким помехам относятся вибрации насосного оборудования, колебания

колонны, турбулентные потоки, а также оптические шумы интеррогатора. В результате отношение сигнал-шум для слабых микросейсмических событий может быть существенно меньше единицы, что резко снижает эффективность традиционных алгоритмов детектирования. Классические методы обнаружения событий STA/LTA, *Semblance* и MLE – основаны на использовании аналитических решающих функций, полученных из физической модели распространения волн [7-9]. Решение о наличии событий принимается путем сравнения значения решающей функции с порогом. Несмотря на физическую обоснованность, такие методы демонстрируют ограниченную устойчивость в условиях реальных скважинных шумов. С одной стороны, понижение порога приводит к лавинообразному росту ложных срабатываний *False Positives*, поскольку шумовые всплески формируют локальные экстремумы решающей функции. С другой стороны, повышение порога с целью подавления шума неизбежно приводит к пропуску слабых событий *False Negatives*, включая процессы образования микротрещин и начальные стадии перетоков.

В последние годы активно развиваются подходы, основанные на методах машинного обучения и глубоких нейронных сетях, демонстрирующие высокую эффективность в задачах автоматического распознавания сейсмических событий при низком SNR [10-13]. Нейросетевые модели способны учитывать сложные нелинейные зависимости между пространственно-временными признаками сигнала, адаптивно моделировать структуры шума и формировать устойчивые критерии принятия решения. Вместе с тем в большинстве работ машинное обучение применяется как полностью альтернативный физике инструмент, что затрудняет интерпретируемость результатов и интеграцию в существующие промышленные алгоритмы. В этой связи актуальной научно-технической задачей является разработка гибридного подхода, сочетающего физическую основу MLE и интеллектуальный анализ признаков. Такой подход позволяет сохранять физическую интерпретируемость базовой модели, одновременно обеспечивая адаптивный учет нестационарного шума и сложной структуры сигнала.

Цель работы заключается в разработке автоматизированного метода детектирования и пространственной локализации микросейсмических событий в данных распределенного акустического зондирования DAS, основанного на использовании функции правдоподобия MLE в сочетании с алгоритмами машинного обучения.

Для достижения поставленной цели решаются следующие **задачи**:

1) Сформировать набор синтетических микросейсмических волновых форм с варьируемыми параметрами источника: пространственное положение, время возникновения, компоненты тензора момента, уровень SNR и интегрировать их в реальные шумовые записи DAS с целью имитации полевых условий регистрации.

2) Реализовать процедуру пространственно-временной локации микросейсмических источников методом максимального правдоподобия MLE и сформировать трехмерные массивы SNRLoc для дальнейшего обучения.

3) Спроектировать и обучить нейросетевую модель для решения задачи бинарной классификации и локализации микросейсмических событий.

4) Выполнить тестирование разработанного метода и провести сравнительный анализ его работы с классическим пороговым детектором.

1. Моделирование волновых форм и формирование базы данных для машинного обучения

Задача моделирования заключается в расчете откликов среды на виртуальные датчики от базовых воздействий по шести независимым компонентам тензора сейсмического момента в области изучения. Скоростная модель задавалась в виде вертикально неоднородной среды, параметры которой изменяются только по глубине. При этом использовались значения скоростей V_p , полученных из данных ВСП, а скорости V_s определялись по линейной зависимости $V_s(V_p)$ из акустического каротажа. Микросейсмический источник задавался в форме импульса с широкополосной временной функцией,

обеспечивающей возбуждение частотного диапазона 75–300 Гц для Р-волн и 75–150 Гц для S-волн. Из-за отсутствия ортогональных компонент регистрации в DAS-системе и невозможности определить азимут прихода волны вблизи абсолютно линейного волоконного тракта задача рассматривается в осесимметричной постановке. Поэтому область изучения представляется двумерной сеткой в координатах глубины Z и радиуса R . Расчеты выполнялись для радиального диапазона от 10 до 180 м, что соответствует реальному пределу чувствительности DAS. Для каждой глубины Z строилась локальная подмодель среды, где средняя скорость определялась по данным ВСП в окрестности тех датчиков, которые участвуют в локации. Ориентация тензора момента варьировалась, включая изотропный тип источника и сдвиговые механизмы, что позволяет получать полный набор направленных откликов. Результатом моделирования являются отклики для шести способов приложения сил на каждую компоненту тензора.

Полученные синтетические волновые формы внедрялись в реальные шумовые записи на соответствующие глубины и моменты времени, что позволяло проводить локацию событий в условиях реального фонового шума и оценивать применимость алгоритмов выделения микросейсмических откликов.

2. Алгоритм локации микросейсмических событий методом MLE, нормализация решающей функции и базовый алгоритм детектирования сейсмического события

Локация микросейсмических событий выполнялась методом максимального правдоподобия (Maximum Likelihood Estimation, MLE), широко применяемым в радиотехнике для оценки параметров сигналов [14]. В рамках задачи детектирования микросейсмических событий метод MLE использовался для оценки параметров сейсмического момента M и положения источника в пространственно-временной области исследования. Предполагалось, что зарегистрированный сигнал на k -м приемнике представляет собой сумму полезного сигнала, обусловленного микросейсмическим событием, и шумовой

компонентой, которая в общем случае может быть пространственно коррелированной. Тогда сигнал на приемнике может быть записан в виде:

$$z_k(t) = n_k(t) + \sum_i^N M^i s_k^i(t), \quad (1)$$

где $n_k(t)$ – шумовая составляющая на k -м канале наблюдения, $s_k^i(t)$ – модельный отклик среды для i -й компоненты тензора сейсмического момента, M^i – соответствующие параметры тензора сейсмического момента. Данный подход к локации сейсмических событий предполагает сканирование в узлах сетки всей области изучения (глубина, радиус, время) на предмет наличия события (вероятностного присутствия модельных откликов с реальными данными). Вне зависимости от того присутствуют ли в данных сейсмические события (сейсмические отклики) методика оценивает значения сейсмического момента M^i для каждой точки изучения для каждого момента времени.

Для количественной оценки достоверности обнаружения событий использовалась функция отношения сигнал/шум $\text{SNRLoc}(M)$, определяемая через оценку параметров тензора сейсмического момента и их ковариационную матрицу:

$$\text{SNRLoc}(M) = M^T \text{cov}(M)^{-1} M, \quad (2)$$

где $\text{cov}(M)$ – ковариационная матрица оценок параметров тензора сейсмического момента; T – обозначает операцию транспонирования. Данная величина характеризует степень уверенности алгоритма в наличии микросейсмического события в рассматриваемой точке пространства и времени. Высокие значения SNRLoc соответствуют областям, в которых модель согласуется с реальными данными.

Для стабилизации процесса детектирования событий исходные значения SNRLoc нормировались на собственную дисперсию фонового шума. Событие детектировалось в глобальном максимуме SNRLoc сетки области изучения в некоторой пространственно-временной окрестности. Для устранения остаточной нестационарности, существующей в массиве SNRLoc , был применен комплекс

последовательных преобразований. Вначале выполнялась нормализация SNR_{Loc} на медианное значение массива в окрестности катящегося окна, что давало возможность выровнять амплитудный уровень SNR_{Loc}. Далее нормированный SNR_{Loc} подвергался сглаживанию, направленному на подавление мелкомасштабных вариаций и восстановление более стабильной статистической структуры массива SNR_{Loc} данных.

Базовый алгоритм детектирования микросейсмических событий основан на анализе трехмерного массива локализаций SNR_{Loc} с координатами (глубина, радиус, время). Исходный массив пространственных временных значений преобразовывался в одномерную временную зависимость $\max \text{SNR}_{\text{Loc}}(t)$, выступающую в качестве решающей функции детектирования. Для этого пространственные координаты (глубина, радиус) сворачивались с использованием функции $\max()$, после чего для функции $\max \text{SNR}_{\text{Loc}}(t)$ вычислялись локальные максимумы во времени, соответствующие потенциальным микросейсмическим событиям.

3. Архитектура модели U-Net для машинного обучения на данных SNR_{Loc}

Архитектура разработанной модели представляет собой трехмерную полностью сверточную нейронную сеть типа кодировщик-декодировщик U-Net, предназначенную для анализа локальных пространственно-временных фрагментов данных DAS. Структурная схема представлена на рисунке 1. Входные данные представлены в виде тензора признаков размерности (C, D, R, T) , где C – число каналов признаков, D – координата вдоль кабеля, R – расстояние от оси скважины, T – временная координата. В качестве целевой переменной использовалась бинарная метка. Такая форма представления позволяет учитывать пространственно-временную когерентность волнового поля в окрестности возможного микросейсмического события.

Кодирующая часть сети encoder осуществляет извлечение иерархических признаков входного сигнала. Каждый уровень включает два трехмерных сверточных оператора с нормализацией признаков и нелинейной функцией

активации. Свертка реализует локальный нелинейный оператор фильтрации, позволяющий выявлять характерные пространственно-временные структуры волновых фронтов. После каждого блока выполняется операция MaxPool (2,2,2), уменьшающая пространственное разрешение. Центральная часть сети формирует компактное представление входного сигнала с максимальным числом каналов и включает стохастическую регуляризацию Dropout для повышения устойчивости обучения.




Рис. 1. Архитектура модели U-net для обучения модели.

Декодер восстанавливает пространственные размеры карт признаков, применяя транспонированные трехмерные свертки. Существенной особенностью архитектуры является использование пропускных соединений skip-connections, объединяющих признаки соответствующих уровней кодировщика и декодера. Благодаря этому модель одновременно учитывает общую структуру сигнала и его локальные особенности, что необходимо для корректного анализа микросейсмических данных.

4. Результаты детектирования событий

Для обучения модели архитектуры U-Net была сформирована синтетическая база данных, включающая в себя реальные данные и модельные отклики микросейсмических событий. Генерация данных выполнялась методом стохастического параметрического моделирования с варьированием пространственных, временных и динамических характеристик источника. Положение источника задавалось случайным образом в пределах глубины 2300-4000 метров и радиального удаления от скважины 10-180 метров. Время возникновения события также выбиралось случайно в интервале 0-2 секунд, что позволило сформировать сигналы с различным положением гиперболических фронтов на сейсмограммах и обеспечить устойчивость модели к изменению временной позиции события. Для моделирования шумовой обстановки отношение сигнал/шум варьировалось в диапазоне 0.2-4, что соответствует условиям от сильно зашумленных до относительно хорошо видимых событий. Вариативность механизма очага задавалась случайным выбором компонент симметричного тензора момента $[m_{xx}, m_{zx}, m_{zz}]$ в диапазоне от -2 до 2, что позволило моделировать различные типы механизмов излучения.

Всего было сгенерировано 1000 синтетических кадров, каждый из которых содержал 45 микросейсмических событий. Такой объем обеспечивает достаточно полное покрытие параметрического пространства и формирует способность модели к обобщению в условиях неопределенности локализации источника, механизма излучения и уровня шума. Сгенерированные данные далее обрабатывались методом максимального правдоподобия (MLE). Результатом локации методом MLE является трехмерный массив распределений функции правдоподобия SNRLoc, описывающий пространственно-временное распределение энергии сигнала. Полученный набор данных был разделен на обучающую, валидационную и тестовую выборки в соотношении 75 %, 10 % и 15 % соответственно. Обучающая выборка использовалась для оптимизации весов нейронной сети, валидационная – для настройки гиперпараметров и

контроля переобучения, а тестовая – для независимой оценки качества детектирования на ранее не наблюдавшихся данных.

Входные данные нейронной сети формируются в виде многоканального пространственно-временного куба признаков, отражающего локальную структуру волнового поля в окрестности предполагаемого микросейсмического события. Размерность входного массива составляет (5, 10, 10, 51). Таким образом, каждый входной куб формируется как локальный фрагмент данных DAS, подлежащий классификации на предмет наличия микросейсмического события или шума. В качестве входных признаков используется пять каналов, полученных из исходных данных SNRLoc с применением различных методов обработки сигналов, как показано на рисунке 2.




Рис. 2. Пример визуализации входных признаков модели.

В верхней строке показаны сечения признаковых кубов в координатах глубина-время, в нижней – в координатах глубина-радиус.

Представлены пять каналов входных данных: SNRLoc, огибающая сигнала по времени, производная по времени, локальная дисперсия и логарифм спектральной энергии.

Первый канал (ch0) соответствует исходному полю SNRLoc, являющимся мерой того, насколько хорошо система локализации видит события. На основе SNRLoc строится решающая функция в классическом алгоритме детектирования события. Второй канал (ch1) представляет собой огибающую SNRLoc, вычисленный с использованием преобразования Гильберта, что позволяет

повысить устойчивость признаков к фазовым изменениям SNR_{loc} . Третий канал (ch2) формируется как временная производная SNR_{loc} , что усиливает быстрые изменения амплитуды. Четвертый канал (ch3) представляет собой локальную дисперсию сигнала, вычисленную в скользящем пространственно-временном окне. Этот признак характеризует степень неоднородности сигнала и позволяет выделять участки повышенной энергии, связанные с микросейсмическими источниками. Пятый канал (ch4) описывает логарифм локальной спектральной энергии поля SNR_{Loc} , вычисленной в скользящем временном окне. Использование логарифмической шкалы позволяет сжать динамический диапазон энергии и повысить чувствительность к слабым событиям. Многоканальное представление данных позволяет модели анализировать волновое поле одновременно во временной и спектральной областях, повышая точность детектирования события в зашумленных данных.

Обработка полного трехмерного массива SNR_{Loc} осуществляется методом скользящего окна. Объем данных последовательно разбивается на перекрывающиеся кубы фиксированного размера (10,10,51) с шагом (4,4,20) и для каждого куба вычисляется вектор локальных статистических признаков. Полученные кубы формируют батчи и подаются на вход модели U-Net. Для каждого куба сеть оценивает вероятность наличия микросейсмических событий. Целевая переменная задается бинарной меткой, где 1 – соответствует наличию событий, а 0 – шуму. Вероятности всех кубов агрегируются в трехмерную карту вероятности размерности исходного массива по правилу softmax вешанного усреднения. Такая схема агрегации подавляет вклад низковоероятностных кубов и усиливает сигнал в областях, детектированных несколькими перекрывающимися кубами. Поскольку каждый скользящий куб независимо оценивает положение ближайшего источника, несколько соседних кубов перекрывает одно событие, формируют плотное облако близких по координатам оценок в пространстве глубина-радиус-время. Для объединения этих локальных оценок применяется метод кластеризации DBSCAN. Координаты события определяются как взвешенный центроид кластера, где веса

задаются предсказанной нейросетевой моделью вероятностью присутствия события в кубе, что обеспечивает наиболее вероятную пространственно-временную локализацию источника. Результат прогнозирования на полном тестовом объеме можно видеть на рисунке 3. Крестиками (обозначение GT, Ground Truth) показаны истинные положения событий, тогда как кластеры точек соответствуют источникам, обнаруженным моделью.




Рис. 3. Проекция результатов детектирования на плоскость глубина-время для тестового объема. Крестиками обозначены истинные положения микросейсмических событий, тогда как кластеры, выделенные алгоритмом DBSCAN, соответствуют источникам, обнаруженным моделью.

Для количественной оценки качества обнаружения микросейсмических событий использовался модифицированный показатель Фоулкса-Маллоуса (Fowlkes-Mallows, FM). Особенность рассматриваемой задачи заключается в отсутствии информативного отрицательного класса: число точек, не относящихся к микросейсмическим событиям, существенно превосходит число событий и формально не ограничено. В таких условиях величина истинно отрицательных срабатываний TN не обладает физически интерпретируемым смыслом. По этой причине использование метрик, непосредственно зависящих от TN, например, коэффициента корреляции Мэттьюса, оказывается затруднительным. Напомним, что MCC определяется следующей формулой:

$$MCC = \frac{TP * TN - FP * FN}{\sqrt{((TP + FP) * (TP + FN) * (TN + FP) * (TN + FN))}}. \quad (3)$$

В условиях сильного дисбаланса классов, характерного для задач детектирования микросейсмических событий, величина TN значительно превышает остальные элементы матрицы ошибок. При этом выражение для MCC асимптотически упрощается и становится пропорциональным метрике Фоулкса-Маллоуса. Поэтому в рассматриваемой работе используется ее эквивалентная формула:

$$FM = \frac{TP}{\sqrt{((TP + FP) * (TP + FN))}}, \quad (4)$$

где TP , FP и FN обозначают число истинно положительных, ложно положительных и ложно отрицательных детекций соответственно. Таким образом, коэффициент FM фактически характеризует геометрическое среднее между точностью *precision* и полнотой *recall* и обеспечивает устойчивую оценку качества детектирования в условиях экстремального дисбаланса классов. Сравнительный анализ двух методов автоматического обнаружения сейсмических событий проводился на десяти независимых тестовых объемах, суммарно содержащих 389 размеченных событий. В качестве базового метода использовался классический детектор на основе пороговой отбраковки решающей функции, в качестве предложенного – метод машинного обучения, реализованный с помощью модели U-Net и последующей кластеризации алгоритмом DBSCAN.

На рисунке 4а показана показатель FM обоих методов для каждого из десяти объемов. Метод ML демонстрирует стабильное превосходство во всех без исключения случаях: значения FM варьируются в диапазоне 0.44–0.57, тогда как для классического метода этот диапазон составляет 0.13–0.27. Средний показатель FM по всем объемам равен 0.514 для ML против 0.174 для CL (рисунок 5b), что соответствует трехкратному превосходству предложенного подхода. Пространственное распределение методов в координатах точность–полнота наглядно иллюстрирует рисунок 4с: точки ML образуют компактное

облако в области высокой точности $Precision \approx 0.55–0.93$ при умеренной полноте $Recall \approx 0.30–0.46$, тогда как точки классического метода сосредоточены в области низких значений обоих показателей.




Рис. 4. Сравнение методов обнаружения сейсмических событий по десяти тестовым объемам. (a) показатель FM метода U-Net на основе кластеризации DBSCAN и классического порогового метода. (b) Структура ошибок детектирования для методов U-Net. (c) Распределение результатов в пространстве точность-полнота *Precision-Recall*.

Детальная разбивка результатов по типам событий TP, FP и FN представлена на рисунках 4b и 5a. Суммарно по всем объемам метод ML обнаружил 146 истинно положительных событий при 66 ложных срабатываниях и 243 пропущенных. Классический детектор при меньшем числе истинных обнаружений 94 TP генерирует на порядок большее число ложных тревог – 668 FP, что принципиально снижает практическую применимость метода. Количественно это выражается в средней точности 0.719 для ML против 0.124 для классического при сопоставимой, но все же более высокой полноте ML: 0.375 против 0.245 (рисунок 5b).




Рис. 5. Агрегированные характеристики методов по всем тестовым объемам.

(а) Суммарное число TP, FP и FN событий для методов двух методов.

(б) Средние значения показателя FM для двух методов.

Анализ детектируемости в зависимости от SNR события представлен на рисунке 6. Гистограмма распределения (рисунок 6а) показывает, что большинство истинных событий сосредоточено в диапазоне SNR от 1 до 3, при этом обнаруженные методом ML события $n = 146$ равномерно представлены во всем диапазоне SNR, тогда как классический метод $n = 94$ обнаруживает преимущественно события с более высоким SNR.

Это различие более наглядно проявляется на рисунке 6б, где показана частота обнаружения событий в четырех интервалах SNR. В областях низких значений SNR интервал с центром около 0.7, классический метод практически не обеспечивает обнаружения, тогда как ML подход сохраняет коэффициент детектирования около 0.19. При $\text{SNR} \approx 2.6$ вероятность обнаружения увеличивается до 0.5 для ML и до 0.32 для классического алгоритма. При этом ни один метод не достигает коэффициента обнаружения выше 0.5, что указывает на высокую сложность задачи детектирования при рассматриваемом уровне шума.

На рисунке 6с показана динамика TP и FP по отдельным объемам. Число ложных срабатываний классического метода остается стабильно высоким и слабо коррелирует с числом истинных событий. Для ML подхода число FP значительно меньше и заметно ниже числа TP, что свидетельствует о высокой избирательности предложенного детектора.

Методика рассчитана на обнаружения слабых событий $\text{SNR} < 1.5$ и использует автоматическую регулировку уровня сигнала на каждом канале. Автоматическая регулировка подавляет нестационарность сигналов и повышает устойчивость стабилизации обучения нейросети. Однако для событий с высоким SNR его импульс приводится к уровню шума, поэтому контраст импульса в смеси сигнала и шума уменьшается. В результате сильный сигнал искажается фильтром и что приводит к снижению точности локализации сильных событий.




Рис. 6. Анализ зависимости детектируемости от отношения сигнал/шум (SNR).

(a) Гистограммы распределения SNR для всех размеченных событий.

(b) Частота обнаружения по SNR для двух методов. (c) Динамика числа TP и FP по отдельным тестовым объемам для обоих методов.

Таким образом, предложенный ML-детектор в первую очередь оптимизирован для выявления слабых событий, которые представляют наибольший практический интерес в условиях высокого уровня шума. В дальнейшем планируется разработка гибридной схемы детектирования и локализации, использующей расширенный набор признаков: помимо SNRLoc будут учитываться дополнительные характеристики, извлекаемые из сейсмограмм. Такой подход должен улучшить обнаружение событий в широком диапазоне SNR, при этом в алгоритме будет учитываться проблема нормализации для сигналов с высоким SNR, приводящая к снижению контрастности сильных событий.

Заключение

В настоящей работе разработан и апробирован автоматизированный метод детектирования и пространственной локализации микросейсмических событий в данных распределенного акустического зондирования DAS. Предложенный подход базируется на гибридной архитектуре, объединяющей классическую статистическую оценку MLE и машинное обучение.

Сформирован синтетический обучающий набор, включающий микросейсмические волновые формы с варьируемыми параметрами источника пространственное положение, время, тензор момента и SNR, интегрированные в реальные шумовые записи DAS. Это позволило воспроизвести условия полевой регистрации и обеспечить достаточный объем данных для настройки модели.

В основе метода лежит процедура формирования трехмерных массивов SNRLoc, сохраняющих физическую интерпретируемость данных. Обработка этих данных выполняется моделью U-Net, которая решает задачу бинарной классификации наличия события. Предсказанные смещения агрегируются алгоритмом кластеризации DBSCAN, что формирует итоговый список обнаруженных событий с точными координатами.

Сравнительное тестирование на десяти независимых объемах данных (389 размеченных событий суммарно) продемонстрировало существенное превосходство разработанного метода над классическим пороговым детектором STA/LTA. Средний показатель FM составил 0.514 против 0.174, а точность – 0.719 против 0.124. Ключевым достижением стало десятикратное сокращение числа ложных срабатываний – с 668 до 66 – при одновременном увеличении числа истинных обнаружений с 94 до 146. Анализ зависимости детектируемости от SNR подтвердил, что нейросетевой подход сохраняет работоспособность в области низкого отношения сигнал/шум, где классический детектор теряет чувствительность.

Полученные результаты показывают, что разработанный алгоритм позволяет существенно повысить надежность автоматического мониторинга микросейсмической активности в данных DAS, обеспечивая более уверенное

обнаружение слабых событий при значительном снижении числа ложных срабатываний. Это создает предпосылки для практического применения метода при интерпретации полевых данных и может стать основой для дальнейшего развития автоматизированных систем микросейсмического мониторинга.

Литература

1. Hartog A.H. An introduction to distributed optical fibre sensors. – Boca Raton : CRC Press, 2017. – 440 p.
2. Lindsey N.J., Rademacher H., Ajo-Franklin J.B. On the broadband instrument response of DAS systems // Journal of Geophysical Research: Solid Earth. – 2020. – Vol. 125, No. 2. – P. e2019JB018145.
3. Mateeva A., Lopez J., Potters H., Mestayer J., Cox B., Kiyashchenko D., Wills P., Grandi S. Distributed acoustic sensing for reservoir monitoring with vertical seismic profiling // Geophysical Prospecting. – 2014. – Vol. 62, No. 4. – P. 679–692.
4. Karrenbach M., Cole S., Ridge A., Boone K., Kahn D. Fiber-optic distributed acoustic sensing of microseismicity // The Leading Edge. – 2019. – Vol. 38, No. 8. – P. 636–642.
5. Li Z., Zhan Z. Pushing the limit of earthquake detection with DAS // Geophysical Journal International. – 2020. – Vol. 221, No. 2. – P. 1343–1359.
6. Daley T.M., Miller D.E., Dodds K., Cook P., Freifeld B. Field testing of distributed acoustic sensing for subsurface monitoring // Geophysics. – 2013. – Vol. 78, No. 2. – P. O1–O13.
7. Allen R.V. Automatic earthquake recognition and timing from single traces // Bulletin of the Seismological Society of America. – 1978. – Vol. 68, No. 5. – P. 1521–1532.
8. Neidell N.S., Taner M.T. Semblance and other coherency measures for multichannel data // Geophysics. – 1971. – Vol. 36, No. 3. – P. 482–497.

9. Tarantola A. Inverse problem theory and methods for model parameter estimation.
– Philadelphia : SIAM, 2005. – 342 p.
10. Yu P., Zhang H., Li X., Chen Y. DASEventNet: AI-based microseismic detection using DAS data // IEEE Transactions on Geoscience and Remote Sensing. – 2024. – Vol. 62. – Art. 5500915.
11. Wamriew D., Saad O.M., Kuleli H.S. Deep neural networks for microseismic detection and location // Sensors. – 2021. – Vol. 21, No. 3. – P. 830.
12. Perol T., Gharbi M., Denolle M. Convolutional neural network for earthquake detection // Science Advances. – 2018. – Vol. 4, No. 2. – eaao1048.
13. Zhu W., Beroza G.C. PhaseNet: a deep-neural-network-based seismic arrival-time picking method // Geophysical Journal International. – 2019. – Vol. 216, No. 1. – P. 261–273.
14. Birialtsev E., Demidov D., Mokshin E. Determination of moment tensor and location of microseismic events under conditions of highly correlated noise based on the maximum likelihood method // Geophysical Prospecting. – 2017. – Vol. 65, No. 1. – P. 1–17.

Для цитирования:

Емельянов Б.В., Шерстюков О.Н., Рыжов В.А. Повышение помехоустойчивости детектирования микросейсмических событий на данных DAS на основе гибридного подхода MLE и модели U-Net // Журнал радиоэлектроники. – 2026. – №. 7. <https://doi.org/10.30898/1684-1719.2026.7.8>