

ПРИМЕНЕНИЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ АНАЛИЗА СПЕКТРАЛЬНЫХ ХАРАКТЕРИСТИК ИСТОЧНИКОВ АКУСТИЧЕСКОЙ ЭМИССИИ В ГОРНЫХ ПОРОДАХ

Пашенко А.Ф., Пашенко Р.А.

Институт проблем управления им. В.А. Трапезникова РАН, Москва, Россия
paschenko_alex@mail.ru, r.pashhenko@mail.ru

Аннотация. Проведен качественный анализ определения спектральных характеристик акустической эмиссии в горных породах с использованием методов машинного обучения. Показано, что такие методы анализа данных позволяют автоматизировать идентификацию событий, повысить точность определения исследуемых частот и прогноза вероятной сейсмической активности.

Ключевые слова: акустическая эмиссия, спектральный анализ, машинное обучение, идентификация событий, прогнозирование сейсмической активности, корнер-частота.

Введение

Акустическая эмиссия (АЭ) — это физический процесс, возникающий при выделении энергии в виде упругих волн вследствие быстрого локализованного изменения структуры материала. В горных породах этот процесс связан с микроструктурными изменениями, такими как образование новых трещин, рост существующих трещин, а также сдвиг по трещинам. Эти процессы приводят к выделению акустической энергии, которая регистрируется датчиками АЭ в виде волновых сигналов. Исследование характеристик этих сигналов играет ключевую роль в оценке состояния материала и прогнозировании возможных сейсмических событий, что особенно важно в горнодобывающей промышленности, геофизике и мониторинге сооружений.

Современные методы регистрации акустической эмиссии генерируют огромные объемы данных. Обработка таких массивов данных требует применения эффективных вычислительных методов, способных не только обработать большие объемы информации, но и выделить из них ключевые закономерности, важные для дальнейшего анализа.

В данном исследовании мы используем машинное обучение для анализа данных акустической эмиссии, собранных на образцах песчаника и гранита. Особое внимание уделено определению корнер-частоты, которая является важной характеристикой, связанной с размером очага и энерговыделением при сейсмическом событии.

Использование методов машинного обучения в данном исследовании позволило:

1. Автоматизировать процесс обработки данных АЭ, включая предобработку сигналов, их спектральный анализ и идентификацию событий.
2. Выявить ключевые закономерности в больших объемах данных, связанные с характеристиками сигналов АЭ.
3. Значительно сократить время обработки данных благодаря параллельной обработке и оптимизации вычислительных ресурсов.

Применение методов машинного обучения в анализе данных акустической эмиссии открывает новые горизонты для изучения процессов, происходящих в горных породах. В данном исследовании мы подробно рассмотрим методологию, результаты и потенциал использования машинного обучения для анализа данных АЭ в горных породах.

1. Экспериментальное оборудование и методика

В настоящем исследовании использовались образцы гранита и песчаника, которые подвергались одноосному сжатию посредством гидравлического пресса INOVA [1] для инициирования акустической эмиссии. Система регистрации акустических волн состояла из 16 пьезоэлектрических датчиков (рис. 1), расположенных на поверхности образца. Система записывала волновые формы сигналов акустической эмиссии со всех 16 датчиков с разрешением 12 бит и частотой оцифровки 2.5 МГц на канал.

Во время эксперимента регистрировались временные ряды сигналов АЭ. Кроме того, с помощью анализа временных рядов определялся энергетический класс каждого события АЭ. Каждый сигнал был привязан к конкретному времени и координатам события. В результате эксперимента было собрано несколько десятков тысяч таких событий. Эти данные сохранялись в бинарном формате.

Процесс обработки данных включал несколько этапов. Сначала проводилась предварительная обработка сигналов, включавшая фильтрацию, нормализацию и приведение данных к единому формату. Затем для каждого события выполнялся спектральный анализ с использованием быстрого преобразования Фурье (FFT), что позволяло получить спектры частот для каждого сигнала. Эти спектры служили основой для дальнейшего анализа и расчета корнер-частоты.

Важным этапом обработки данных являлась калибровка датчиков, которая подробно описана в работе [2].

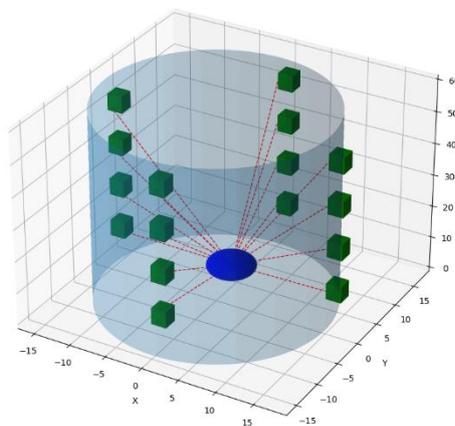


Рис. 1. Схематическое изображение образца горной породы с прикрепленными к нему пьезоэлектрическими датчиками (зеленые кубики), источником АЭ (синяя сфера), трассами, соединяющими источник с разными датчиками

2. Теория расчёта характеристик очагов АЭ

В сейсмологии принято описывать сейсмический очаг с помощью различных моделей. Одной из таких моделей является модель Брюна, которая и легла в основу данной работы. Модель Брюна очень удобна при проведении исследования очага землетрясения в частотной области.

Согласно модели Брюна, очаговый спектр смещений [3] полностью описывается уровнем плоского участка спектра и его точкой излома — корнер-частотой [4], [5] (см. рис. 2). Корнер-частота f_0 является точкой пересечения в двойном логарифмическом масштабе двух прямых, а именно плоского ($\sim f^0$) участка спектра на низких частотах и его асимптотически прямолинейного спада по $\sim f^{-2}$ на высоких частотах. Низкочастотное плато связано с корнер-частотой приведенным ниже соотношением:

$$\Omega(f) = \frac{\Omega_0}{1 + \left(\frac{f}{f_0}\right)^2}, \quad (1)$$

где Ω_0 – амплитуда низкочастотной области спектра смещений.

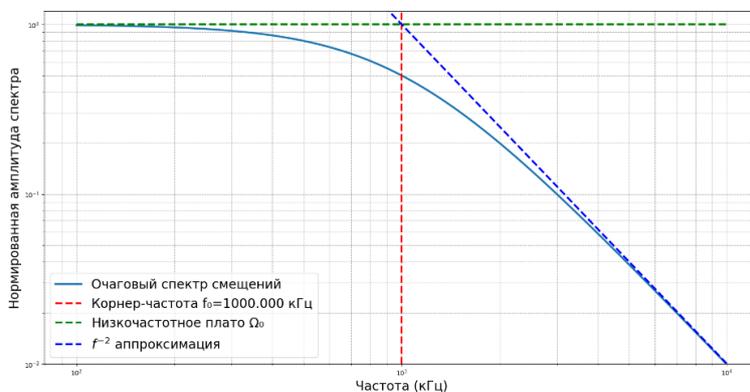


Рис. 2. Очаговый спектр смещений в модели Брюна

Корнер-частота f_0 связана с размером очага (радиусом трещины) следующим соотношением [6]:

$$r = \frac{0.37C_s}{f_0}, \quad (2)$$

где r – радиус трещины; C_s – скорость поперечной волны.

Корнер-частота является важной величиной, которая будет использоваться нами в дальнейшем.

3. Методы машинного обучения в анализе событий акустической эмиссии

Традиционные методы обработки сигналов требуют значительных вычислительных ресурсов и времени при работе с большими объемами данных. Машинное обучение позволяет автоматизировать и ускорить этот процесс.

В данном исследовании мы рассматривали более чем 80 000 событий акустической эмиссии. В процессе подготовки данных к записанным бинарным файлам были применены методы фильтрации сигналов, чтобы удалить шумы и другие артефакты, которые могли исказить результаты анализа.

После фильтрации данные были нормализованы, что позволило привести их к единой шкале. Далее для каждого сигнала были извлечены ключевые признаки (таблица 1). Эти признаки формировали набор данных, пригодный для использования в моделях машинного обучения.

В процессе отбора ключевых признаков особое внимание уделялось их физическому смыслу и взаимосвязи с корнер-частотой. В частности, были исключены такие признаки, как число датчиков, зафиксировавших событие акустической эмиссии, и максимальная амплитуда сигнала. Эти признаки были исключены как из-за их тесной корреляции с основными признаками, так и из-за того, что они могли бы вносить избыточную информацию в модель, снижая её общую производительность.

Одной из важнейших задач данного исследования было прогнозирование корнер-частоты на основе других имеющихся признаков.

Таблица 1. Основные признаки, извлеченные из сигналов акустической эмиссии

Признак	Описание
Время события (Event Time)	Время возникновения события, зафиксированное в момент регистрации сигнала.
Координаты события (Event Coordinates)	Местоположение события в пространстве (X, Y, Z), определяемое с использованием данных с нескольких датчиков.
Энергетический класс (Energy Class)	Категоризация события на основе его энергетической значимости, определенная по характеристикам сигнала.
Корнер-частота (Corner-frequency)	Частота, при которой происходит переход от низкочастотной к высокочастотной области в спектре сигнала.

Для того, чтобы обеспечить максимально возможную точность и минимально возможное время расчета корнер-частот, были проанализированы различные модели машинного обучения. Важно отметить, что для повышения точности и снижения вероятности переобучения модели для всех приведенных далее алгоритмов применялась кросс-валидация. Нами были рассмотрены четыре различных модели машинного обучения — случайный лес (Random Forest), градиентный бустинг (XGBoost), метод опорных векторов для регрессии (Support Vector Regression, SVR) и многослойный перцептрон — для предсказания корнер-частот в данных акустической эмиссии. Каждая из этих моделей обладает уникальными характеристиками, которые определяют их пригодность для решения задач, связанных с анализом сложных нелинейных зависимостей в данных.

Случайный лес — это ансамблевый метод, представляющий собой комбинацию нескольких решающих деревьев, каждое из которых обучается на случайной подвыборке признаков (рис. 3) и объектов из исходного набора данных. Каждое дерево принимает решение независимо, и итоговый результат работы модели представляет собой усредненное значение всех деревьев. Алгоритм реализует процедуру bagging (bootstrap aggregating), которая позволяет значительно снизить дисперсию модели и, следовательно, уменьшить переобучение.

Для каждого объекта x_i в наборе данных X дерево решений строит предсказание $h_m(x_i)$. Итоговое предсказание ансамбля из M деревьев определяется как:

$$\hat{y} = \frac{1}{M} \sum_{m=1}^M h_m(x_i). \quad (3)$$

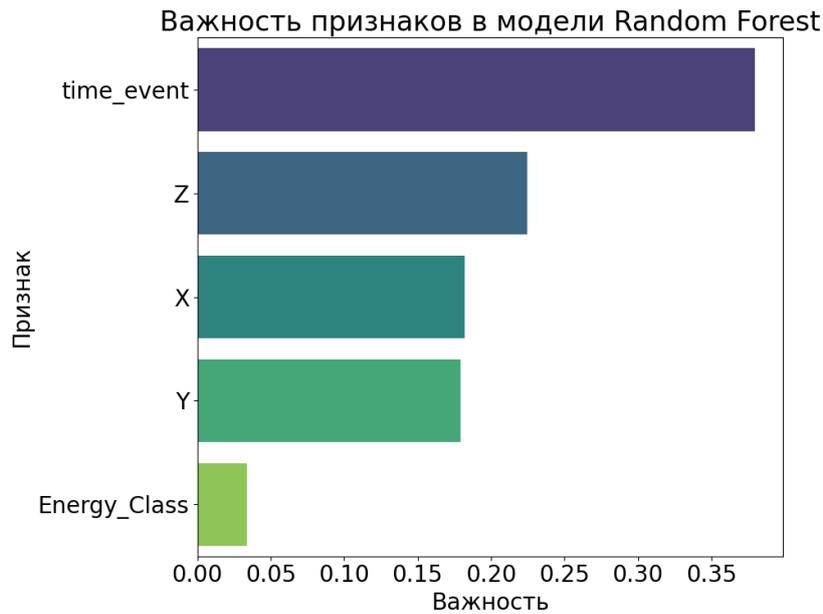


Рис. 3. Важность признаков в модели Random Forest. График демонстрирует относительный вклад каждого признака в предсказание корнер-частот

XGBoost (eXtreme Gradient Boosting) [7] — это метод градиентного бустинга, который строит ансамбль деревьев, каждое из которых корректирует ошибки, допущенные предыдущими деревьями. Основное преимущество XGBoost заключается в его способности минимизировать функцию потерь на каждом этапе, добавляя новые деревья, которые фокусируются на ошибках, сделанных предыдущими деревьями. Важно отметить, что с увеличением размера обучающей выборки, модель демонстрирует устойчивое снижение ошибки на валидационных данных, что можно видеть на кривых обучения (см. рис. 4).

В контексте градиентного бустинга, новое дерево $h_m(x_i)$ добавляется таким образом, чтобы минимизировать функцию потерь $L(y_i, \hat{y}_i)$. Итоговое предсказание определяется как:

$$\hat{y}_i = \sum_{m=1}^M \gamma_m h_m(x_i), \quad (4)$$

где γ_m — коэффициент, определяющий вклад нового дерева в итоговое предсказание.

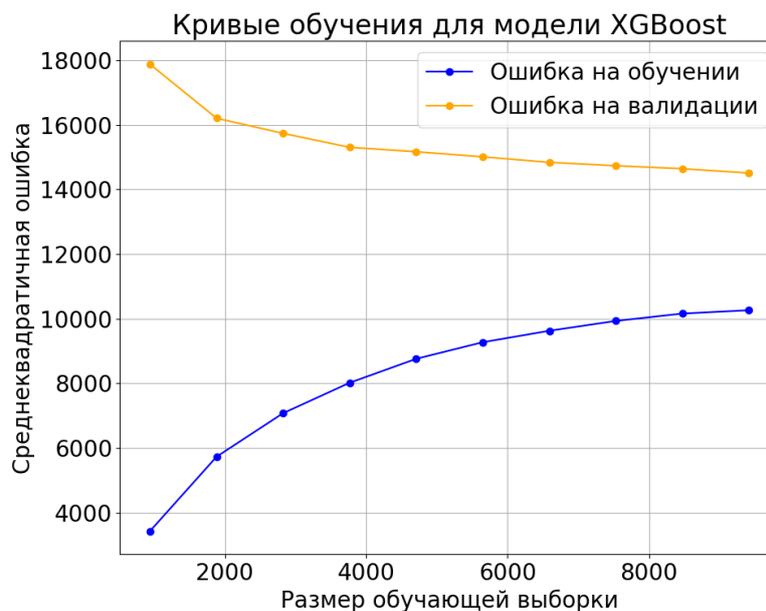


Рис. 4. Кривые обучения для модели XGBoost. График показывает, как изменяется ошибка модели на тренировочных и валидационных данных по мере увеличения размера обучающей выборки

Support Vector Regression [8] — это метод регрессии, основанный на принципе опорных векторов, который показывает хорошую производительность на меньших наборах данных. Однако, как показано на диаграмме остатков (см. рис. 5), эта модель может демонстрировать большие отклонения для некоторых предсказаний, что указывает на необходимость тщательной настройки гиперпараметров для достижения наилучших результатов. В основе SVR лежит задача минимизации функционала, который включает в себя ошибку предсказания и штраф за сложность модели. Основная идея заключается в нахождении гиперплоскости, которая минимизирует отклонение от истинных значений с учетом некоторого допустимого отклонения ε .

SVR минимизирует следующий функционал:

$$\frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n \max(0, |y_i - f(x_i)| - \varepsilon), \quad (5)$$

где C — гиперпараметр, регулирующий баланс между шириной полосы, внутри которой допускаются ошибки, и штрафом за ошибки, выходящие за пределы этой полосы.

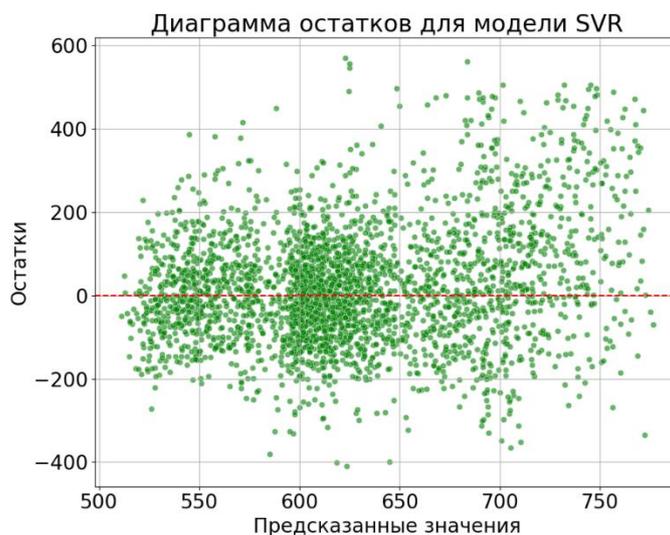


Рис. 5. Диаграмма остатков для модели SVR. График показывает распределение ошибок предсказаний относительно истинных значений, что позволяет оценить качество предсказаний модели

Многослойный перцептрон (MLP) [9] — это универсальный аппроксиматор, способный моделировать сложные нелинейные зависимости в данных. Модель представляет собой последовательность слоев нейронов, каждый из которых выполняет линейное преобразование входных данных с последующим применением нелинейной функции активации. В контексте нашей задачи мы использовали архитектуру с несколькими скрытыми слоями и функцией активации ReLU (Rectified Linear Unit).

Математически, выход каждого нейрона h_j на скрытом слое определяется как:

$$h_j(x) = \sigma(\sum_{i=1}^n \omega_{ij}x_i + b_j), \quad (6)$$

где σ — функция активации, ω_{ij} — веса нейронных связей, b_j — смещение.

Процесс обучения заключается в минимизации функции потерь, например, среднеквадратичной ошибки (MSE), с использованием алгоритма обратного распространения ошибки и градиентного спуска.

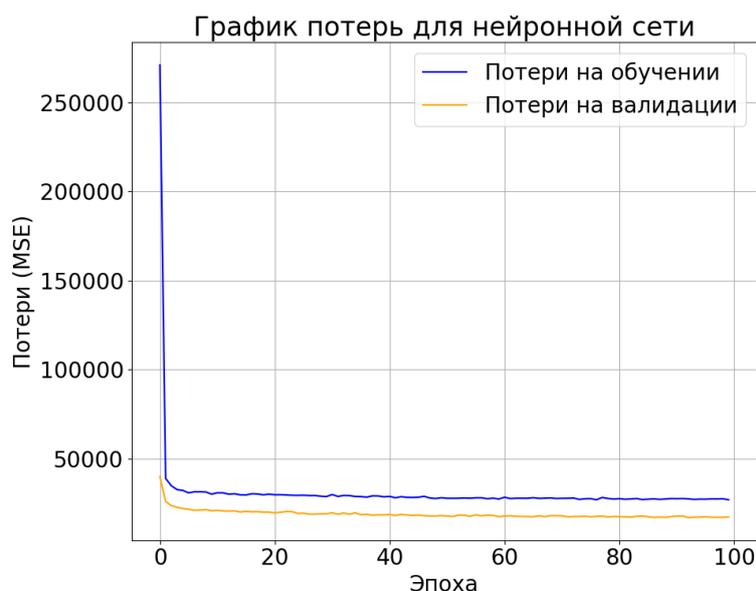


Рис. 6. График потерь для нейронной сети. График демонстрирует динамику изменения потерь на обучающей и валидационной выборках по мере увеличения количества эпох

В таблице 2 показаны сравнения времени обучения и предсказания для разных моделей. Из результатов видно, что XGBoost наиболее эффективна с точки зрения скорости обучения и предсказания. Случайный лес показал сбалансированные результаты, обеспечивая разумное время обучения и быстрое предсказание. Модель SVR показала отличные результаты на небольших объемах данных, но ее вычислительная сложность существенно возрастает с увеличением размера данных. Многослойный перцептрон, несмотря на его длительное время обучения, продемонстрировал хорошие результаты при предсказаниях. График потерь на обучающей и валидационной выборках (см. рис. 6) показывает, что модель эффективно обучалась, постепенно снижая ошибку предсказаний по мере увеличения числа эпох. Это свидетельствует о стабильности модели и её способности к обобщению.

В данном исследовании точность предсказаний была оценена с использованием коэффициента детерминации (R^2). Коэффициент R^2 является стандартной метрикой для оценки качества модели регрессии и показывает, какая доля дисперсии зависимой переменной объясняется моделью. Его значения варьируются от 0 до 1, где значение 1 указывает на идеальное соответствие модели данным, а значение 0 означает, что модель не объясняет никакой вариации зависимой переменной. Этот подход позволяет наглядно увидеть, насколько хорошо модель предсказывает корнер-частоту на основе выбранных признаков. Таким образом, модели, которые показали более высокие значения R^2 , считаются более точными в контексте данного исследования.

XGBoost показал наилучшую точность среди всех рассмотренных моделей (см. рис. 7), что объясняется его способностью адаптироваться к сложным зависимостям в данных. Однако случайный лес также продемонстрировал высокую точность и устойчивость. SVR и MLP, в свою очередь, показали заметно более низкую точность.

Таблица 2. Сравнение времени выполнения расчетов для различных моделей машинного обучения

Модель	Время обучения (с)	Время предсказания (с)
Random Forest	7.468591	0.073997
XGBoost	0.609834	0.026507
SVR	7.238366	1.597015
MLP	9.886170	0.010912

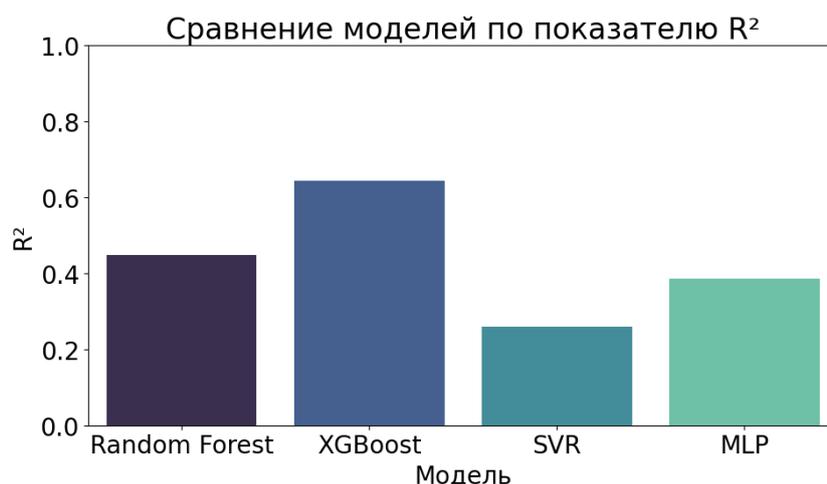


Рис. 7. Сравнение точностей моделей по величине коэффициента детерминации

4. Заключение

В результате проведенного исследования был осуществлен анализ спектральных характеристик источников акустической эмиссии в горных породах с использованием методов машинного обучения. Применение таких методов позволило не только значительно ускорить процесс обработки данных, но и повысить точность прогнозирования корнер-частот — важного параметра, характеризующего размеры и энерговыделение очагов сейсмических событий.

Результаты показали, что каждая из использованных моделей машинного обучения обладает своими преимуществами и ограничениями. Метод случайного леса и градиентный бустинг продемонстрировали приемлемую точность предсказаний, при этом XGBoost показал наилучший результат по коэффициенту детерминации. Это объясняется способностью XGBoost эффективно адаптироваться к сложным нелинейным зависимостям в данных, минимизируя ошибки на каждом этапе построения модели.

Метод опорных векторов для регрессии (SVR) оказался менее эффективным на больших объемах данных, однако продемонстрировал отличные результаты на меньших выборках, что делает его подходящим для специфических задач. Многослойный перцептрон проявил себя как мощный инструмент для моделирования сложных зависимостей, однако требовал значительных вычислительных ресурсов и тщательной настройки гиперпараметров.

На основе полученных данных можно сделать вывод, что комбинирование различных методов машинного обучения и тщательный подбор параметров моделей позволяет достичь высоких результатов в анализе данных акустической эмиссии. В частности, XGBoost и случайный лес могут быть рекомендованы для использования в задачах прогнозирования корнер-частот в условиях работы с большими данными, где важна как точность, так и скорость вычислений.

Таким образом, использование машинного обучения в анализе сигналов акустической эмиссии открывает новые возможности для исследования сейсмической активности в горных породах, предлагая эффективные инструменты для автоматизации обработки данных и улучшения точности предсказаний [10].

Литература

1. Патонин А.В., Пономарев А.В., Смирнов В.Б. Сейсмические приборы. – 2013. – Т. 49, № 1. – С. 19–34.
2. Пащенко, Р.А. Спектральные характеристики источников акустической эмиссии в горных породах // Ученые записки физического факультета Московского университета, № 3, 2024. С. 1-7. DOI: 10.1007/s10921-012-0131-2.
3. Касахара К. Механика землетрясений: Пер. с англ. – М.: Мир, 1985. – 264 с.
4. Brune J.N. J. Geophys. Res. – 1971. – Vol. 76. – P. 5002.
5. Аки К., Ричардс П. Количественная сейсмология. Теория и методы. Том 2. – М.: Мир, 1983. – 772 с.
6. Nelder J.A., Mead R. Computer Journal. – 1965. – Vol. 7. – P. 308–313.
7. Tianqi Chen and Carlos Guestrin, "XGBoost: A Scalable Tree Boosting System", Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 2016. DOI: 10.1145/2939672.2939785.

8. *Christopher J. C. Burges*, "A Tutorial on Support Vector Machines for Pattern Recognition", *Data Mining and Knowledge Discovery*, 1998. DOI: 10.1023/A:1009715923555.
9. *Ian Goodfellow, Yoshua Bengio, Aaron Courville*, "Deep Learning", MIT Press, 2016. ISBN: 978-0262035613.
10. *Ethem Alpaydin*, "Introduction to Machine Learning", MIT Press, 2014. ISBN: 978-0262028189.