

УДК 549

*Каримова Д.А., Верзунов С.Н.**Институт машиноведения и автоматизации ИАН КР**d-k-90@internet.ru, verzunov@hotmail.com*

ПРИМЕНЕНИЕ МАШИННОГО ОБУЧЕНИЯ В РАЗРАБОТКЕ ИНТЕЛЛЕКТУАЛЬНОЙ СИСТЕМЫ АНАЛИЗА ГЕОМАТЕРИАЛОВ

В статье исследуется производительность моделей машинного обучения с целью использования их в интеллектуальных системах анализа геоматериалов, в частности, при решении задачи классификации геоматериалов на основе временных рядов амплитуды и фазы прошедших через образец геоматериала электромагнитных волн. В ходе исследования были рассмотрены и сравнены модели сверточной нейронной сети (CNN), долгой краткосрочной памяти (LSTM), многослойного персептрона (MLP) и ближайших соседей (KNN). Модель CNN демонстрирует высокую точность и эффективность в классификации геоматериалов, в то время как другие модели требуют дополнительной настройки для улучшения их производительности. Для дальнейших исследований возможно усовершенствование модели CNN и её адаптация к различным геологическим задачам.

Ключевые слова: искусственный интеллект, машинное обучение, геоматериалы, классификация, сверточные нейронные сети (CNN), сети долгой краткосрочной памяти (LSTM), многослойный персептрон (MLP), метод ближайших соседей (KNN), IQ-детекция, точность, функция потерь, обучающая выборка.

Введение. Современные технологии и методы машинного обучения играют важную роль в разнообразных областях науки и промышленности, предоставляя новые возможности для анализа данных и классификации объектов. Машинное обучение представляет собой подраздел искусственного интеллекта, который позволяет извлекать закономерности из данных и делать прогнозы на основе этих закономерностей [1,2]. Одно из актуальных направлений применения машинного обучения – геологические исследования, в которых основной задачей является определение физических свойств горных пород и их классификация на основе разнообразных характеристик. Горные породы представляют собой естественные минеральные агрегаты, образовавшиеся в результате остывания расплавленной магмы, накопления осадков, преобразования ранее существующих пород в процессе метаморфизма и залегающие в земной коре в виде самостоятельных геологических тел [3]. Горные породы имеют разнообразные физические и химические свойства, что делает их уникальными в их составе и структуре. Особенно важной представляется разработка подходов к автоматизации мониторинга геоэкологической среды [4] и выявлению изменений, связанных с горными образованиями. Это позволяет эффективно реагировать на экологические угрозы, предотвращать природные катастрофы и обеспечивать устойчивое использование георесурсов.

Одним из основных методов, который может быть успешно применен к задаче анализа горных пород, является классификация на основе машинного обучения [5]. Интеграция моделей машинного обучения в анализ образцов горных пород открывает новые перспективы для более точной классификации и выявления скрытых характеристик.

Традиционные методы сбора и анализа данных в геоэкологии имеют свои ограничения. Они ограничены в масштабах и времени, что затрудняет наблюдение за геоэкологическими процессами на больших территориях и в реальном времени. Кроме того, ручная обработка данных подвержена человеческой ошибке и требует значительных ресурсов, включая трудовые и временные. Сложность и динамика геоэкологической среды могут также

затруднять выявление тенденций и закономерностей, что существенно для принятия обоснованных решений и прогнозирования будущих событий [4].

Учитывая вышесказанное, основным решением указанных проблем является разработка интеллектуальной системы анализа горных пород, способной автоматизировать сбор, обработку и анализ данных о горных породах с использованием методов искусственного интеллекта и машинного обучения. Это позволит сократить время и ресурсы, затрачиваемые на анализ, повысить точность измерений и анализа, а также обеспечить более высокую степень адаптируемости системы к изменяющимся условиям.

В рамках данной работы рассматриваются возможности создания различных моделей машинного обучения, способных автоматически классифицировать и анализировать геоматериалы (горные породы) на основе собранных данных – временных рядов амплитуды и фазы прошедших через образец геоматериала электромагнитных волн. Временные ряды сигналов предоставляются СВЧ-датчиками и аппаратно-программными средствами их обработки. Техническая реализация используемого для сбора данных оборудования подробно описана в работе [6].

Таким образом, целью данного исследования является разработка и оценка моделей машинного обучения для классификации геоматериалов (горных пород). Положенная в основу работы гипотеза предполагает, что выбранные модели машинного обучения, такие как Convolutional Neural Network (CNN), Multilayer Perceptron (MLP), Long Short-Term Memory (LSTM) и метод ближайших соседей (KNN), демонстрируют способность извлекать характеристики из временных рядов горных пород и классифицировать их с высокой точностью.

Результаты этой работы могут иметь практическое применение в геологии, обеспечивая более точные и автоматизированные методы анализа горных пород.

Далее в статье представлены описание природы исходных данных и методов исследования, положенных в основу работы, выбор архитектур моделей машинного обучения и их обучение, результаты экспериментов и обсуждение полученных результатов, а также выводы, обобщающие значимость данного исследования в контексте практических применений в геологических исследованиях.

Методы исследования и исходные данные. Для обучения модели машинного обучения в работе были использованы данные, включающие в себя измерения амплитуды и фазы сигналов, полученных с помощью специальных датчиков и измерительных технологий, способных регистрировать изменения электромагнитной волны, прошедшей сквозь образец горной породы.

Эти измерения были возможны благодаря использованию микрополосковых антенн, работающих совместно с двойными комплементарными разомкнутыми ячейками-резонаторами. Данные антенны генерируют электромагнитные сигналы в узком диапазоне частот и концентрируют их на образце горной породы [7]. После прохождения через образец измененный сигнал принимается другой антенной. Собранные данные позволили анализировать взаимодействие сигналов с горными породами, в результате которого различные физические характеристики пород могут влиять на амплитуду и фазу сигналов.

Параметры сигнала, включая амплитуду и фазу, были получены с помощью открытого программного инструментария GNU Radio [8], оно же использовалось для генерации сигналов в ходе измерений. В качестве зондирующего сигнала использовалась синусоида с частотой в 3.21 гигагерца (3.21 GHz); скорость дискретизации (SampleRate) составляла 20 мегасемплов в секунду (20 MSps), то есть, каждую секунду сигнал оцифровывается 20 миллионов раз.

Принимаемый сигнал также представляет собой синусоиду, амплитуда и фаза которой изменяется в зависимости от диэлектрической проницаемости и проводимости образца.

Устройство HackRF [9], использованное в качестве аппаратной части системы как SDR (Software Defined Radio) устройство, выдаёт комплексные значения на выходе, потому что они представляют собой IQ-сигналы (In-phase and Quadrature signals). Такое синхронное детектирование позволяет оцифровать и точно воспроизвести радиосигналы (рис. 1) [10].

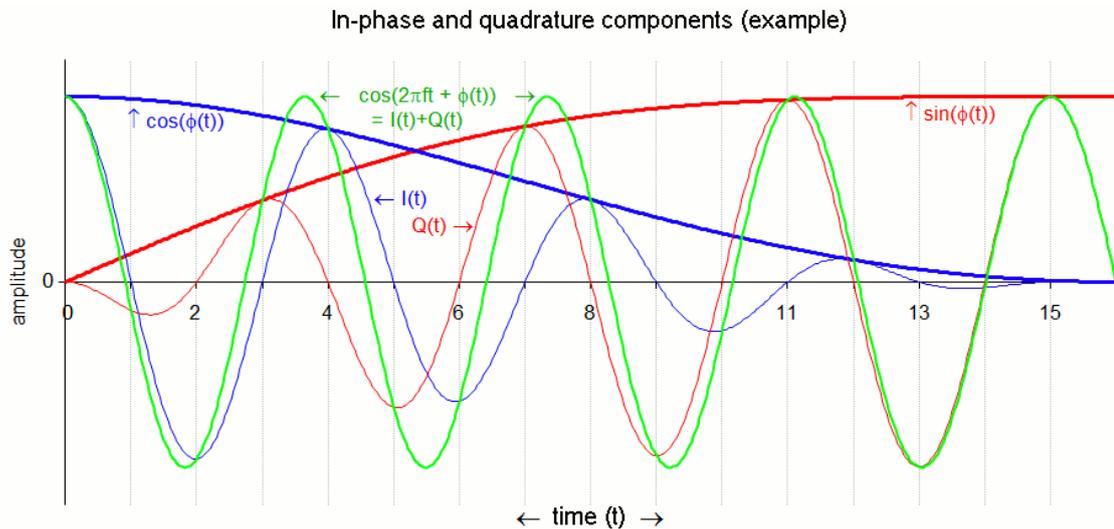


Рисунок 1 – Сигнал (зелёная линия) разлагается в две составляющие: синфазную (синяя линия) и квадратурную (красная линия)

In-phase (I) компонент: представляет собой сигнал, синхронизированный с опорным генератором. Это позволяет измерять амплитуду и фазу волн. Quadrature (Q) компонент: сдвинут по фазе на 90 градусов относительно опорного сигнала. Это расширяет возможности обработки сигналов, позволяя различать сигналы, перемещающиеся в противоположных направлениях.

После применения синхронного детектирования получаются две компоненты во временной области: действительная I и мнимая Q, которые вместе образуют комплексный сигнал (рис. 2). Размер сигнала составляет 1024 тысячи выборок, и шаг по времени составляет 10 мс.

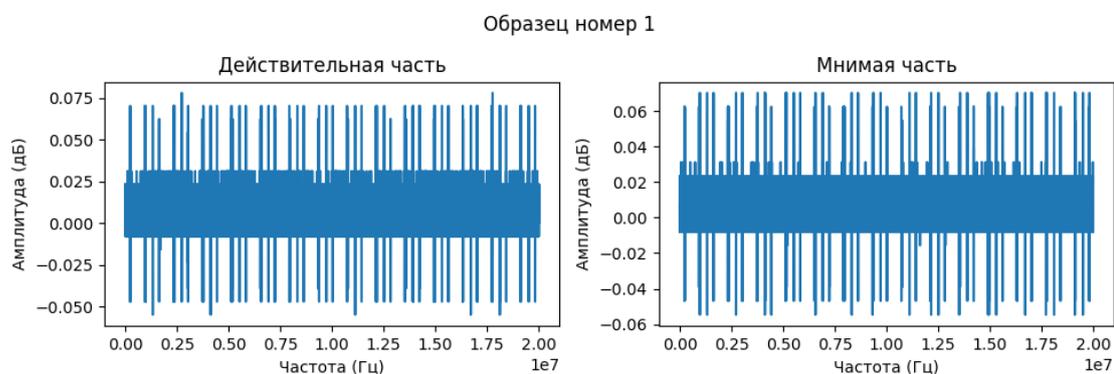


Рисунок 2 – Спектральный анализ сигнала после IQ-детекции: смесь сигнала и шума

Процесс создания и обработки комплексных значений в HackRF или любом другом SDR-устройстве можно описать следующим образом. Прием радиосигнала: HackRF принимает аналоговый радиосигнал, который является электромагнитной волной, распространяющейся через пространство. Аналоговый сигнал преобразуется в цифровую форму с помощью

аналого-цифрового преобразователя (АЦП). Чтобы выделить I- и Q-компоненты, оцифрованный сигнал смешивается с двумя опорными сигналами. Эти опорные сигналы идентичны по частоте, но сдвинуты по фазе на 90 градусов относительно друг друга. Опорный сигнал, синхронизированный по фазе с оригинальным сигналом, используется для выделения I- компонента. Опорный сигнал, сдвинутый на 90 градусов, используется для выделения Q-компонента. Комплексные значения, представленные как пары I и Q, позволяют выполнить множество операций, таких как фильтрация, демодуляция и другие виды обработки сигналов. В данном случае данные об амплитуде и фазе сигнала дают необходимые признаки для обучения моделей машинного обучения с целью классификации и анализа образцов горных пород [9].

В рамках данного исследования были рассмотрены четыре различные модели машинного обучения для решения задачи классификации горных пород на основе детектированных сигналов. Каждая из этих моделей обладает своими уникальными характеристиками и способностями, что делает их подходящими для анализа и классификации данных.

Одним из перспективных подходов к анализу временных рядов является использование сверточных нейронных сетей, таких как CNN (Convolutional Neural Network) [11-13]. Принцип работы CNN основан на использовании сверточных слоев для извлечения признаков из данных. После применения синхронного детектирования получаются две основные компоненты: действительная и мнимая. CNN, показанная на рисунке 3, способна анализировать эти компоненты как изображения в частотной области. Сверточные слои позволяют выявить локальные зависимости между различными фазами и амплитудами в сигнале, что важно для выявления уникальных физических характеристик разных горных пород.

```
Model: "sequential"
```

Layer (type)	Output Shape	Param #
conv1d (Conv1D)	(None, 2, 256)	768256
max_pooling1d (MaxPooling1D)	(None, 1, 256)	0
flatten (Flatten)	(None, 256)	0
dense (Dense)	(None, 64)	16448
dense_1 (Dense)	(None, 5)	325

Рисунок 3 – Архитектура модели CNN

Другой моделью, рассматриваемой в данной работе, является рекуррентная нейронная сеть, а именно, ее вариант – сеть долгой краткосрочной памяти LSTM (Long Short-Term Memory) [14, 15]. Эти сети способны учитывать временные зависимости. Для того чтобы учесть изменения фазы сигнала, необходимо принять во внимание множество отсчетов временного ряда, и LSTM-сеть, показанная на рисунке 4, отлично подходит для анализа таких последовательных данных. После IQ детектирования модель может анализировать динамику изменений в фазе и амплитуде спектров [10].

```
Model: "sequential_4"
```

Layer (type)	Output Shape	Param #
lstm_12 (LSTM)	(None, 4, 256)	20743168
lstm_13 (LSTM)	(None, 4, 128)	197120
lstm_14 (LSTM)	(None, 64)	49408
dense_4 (Dense)	(None, 5)	325

Рисунок 4 – Архитектура модели Long Short-Term Memory (LSTM)

Третьей моделью был многослойный перцептрон (Multi-Layer Perceptron, MLP) [16], простая нейронная сеть (рис. 5). Включение MLP в эксперимент позволяет оценить, насколько эффективны сверточные и рекуррентные архитектуры в сравнении с более классическими моделями.

```
Model: "sequential"
```

Layer (type)	Output Shape	Param #
flatten (Flatten)	(None, 80000)	0
dense (Dense)	(None, 256)	20480256
batch_normalization (Batch Normalization)	(None, 256)	1024
dense_1 (Dense)	(None, 128)	32896
batch_normalization_1 (Batch Normalization)	(None, 128)	512
dense_2 (Dense)	(None, 64)	8256
dense_3 (Dense)	(None, 5)	325

Рисунок 5 – Архитектура модели Multilayer Perceptron (MLP)

Четвертой моделью в исследовании была модель на основе метода ближайших соседей (k-Nearest Neighbors, KNN) [17], который использует расстояния между данными для классификации. KNN работает на идее близости объектов в пространстве признаков после синхронного детектирования. Для каждого объекта предсказания вычисляется расстояние до ближайших соседей из обучающей выборки. Объекту присваивается метка класса, преобладающая среди k ближайших соседей. Архитектура KNN довольно проста и не включает в себя слои и параметры, поэтому эта модель была включена в эксперимент для сравнения с нейронными сетями.

Выбор этих моделей обоснован уникальными характеристиками данных после синхронного детектирования, CNN и LSTM способны учитывать временные зависимости, что делает их подходящими для анализа данных этого типа. MLP и KNN были включены в эксперимент для сравнения с классическими методами и для оценки, насколько нейронные сети могут улучшить производительность.

Результаты. В рамках исследования была проведена оценка производительности четырех разработанных моделей машинного обучения. Модели были сравнены на основе метрик точности и потерь на обучающем и валидационном наборах данных [18,19]; они позволили оценить, насколько успешно та или иная модель способна обобщать свои знания и навыки на реальные данные, которые не использовались в процессе обучения.

Для этой цели подготовлен специальный набор данных, включающий временные ряды, описывающие особенности различных горных пород. В наборе данных учтены факторы

шума и аномалии (выбросы), чтобы сделать тестовый сценарий максимально близким к реальным условиям. Это позволило получить более объективные результаты и оценить производительность моделей в условиях, приближенных к реальным задачам геологии и горнодобывающей промышленности.

Измерения проводились в двух разных расположениях образцов относительно датчиков, что дало в итоге четыре признака: по два ряда для действительной и мнимой частей сигнала (рис. 6). Это позволило учесть различные краевые эффекты и обеспечить более полное и точное представление данных.

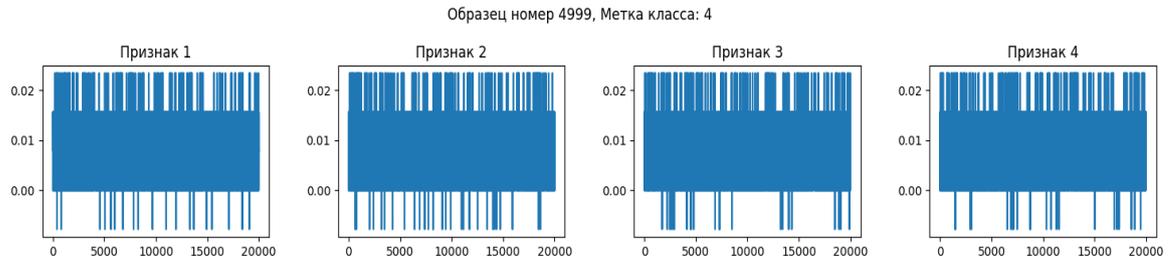
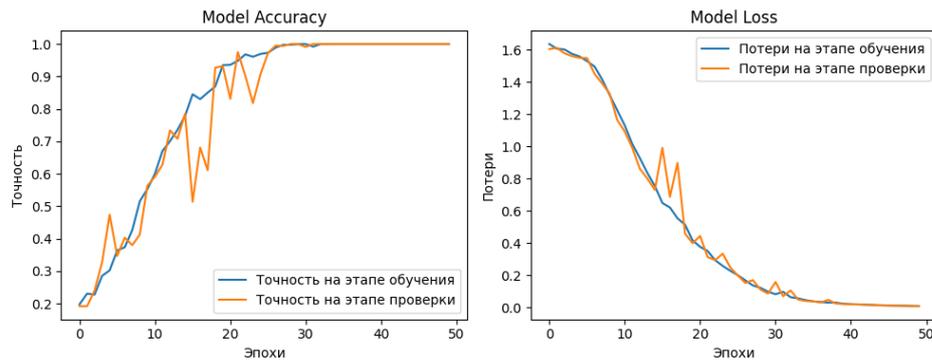
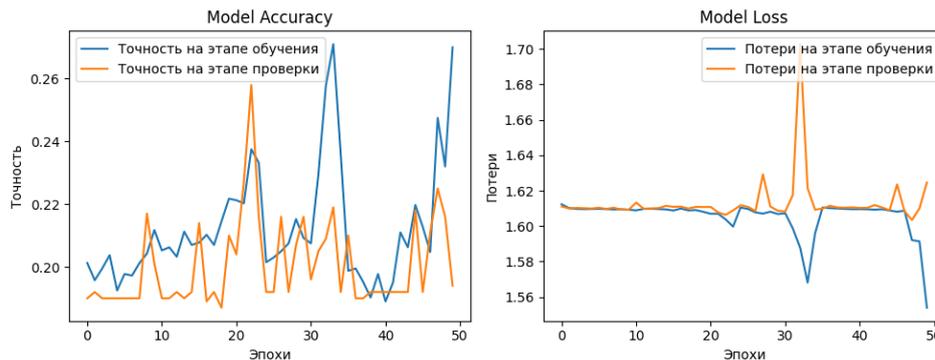


Рисунок 6 – Визуализация заданного образца, содержащего 4 признака

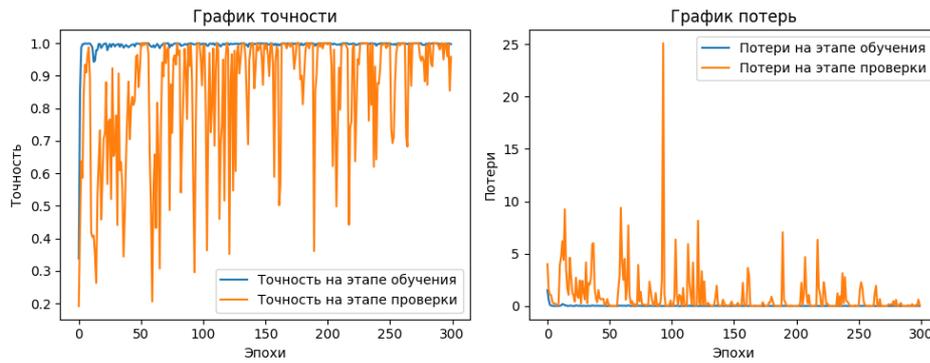
На рисунке 7 представлены результаты обучения четырех рассмотренных моделей в виде графиков функции потерь и точности на обучающей и валидационной выборках.



а)



б)



в)

Рисунок 7 – Графики функции потерь и точности: а) модель 1 Convolutional Neural Network (CNN), б) модель 2 Long Short-Term Memory (LSTM), в) модель 3 Multilayer Perceptron (MLP)

Обсуждение результатов. Модель CNN продемонстрировала последовательное улучшение своих показателей в течение процесса обучения (рис. 7а). К концу обучения точность модели на обучающем и валидационном наборах данных достигла высоких значений с минимальными потерями. Это свидетельствует о высоком качестве модели и успешном обучении, несмотря на признаки переобучения.

В отличие от CNN модель LSTM к концу обучения имеет резкое повышение точности на обучающем наборе данных (рис. 7б). Этот процесс сопровождался скачками, колебаниями точности и потерь на этапах обучения и проверки. Модель LSTM проявила нестабильность.

Модель MLP достигла высокой точности как на обучающем, так и на валидационном наборе данных, но наблюдаются признаки переобучения (оверфиттинга). Графики точности и потерь на этапе проверки характеризуются нестабильностью, но при увеличении числа эпох модель стремится к стабилизации (рис. 7в).

Касательно модели KNN, она демонстрировала более низкую точность по сравнению с нейронными сетями. Модель KNN не способна предсказывать классы с высокой точностью, и ее предсказания часто значительно отличаются от реальных меток классов, что делает ее менее подходящим выбором для данной задачи (рис. 8).

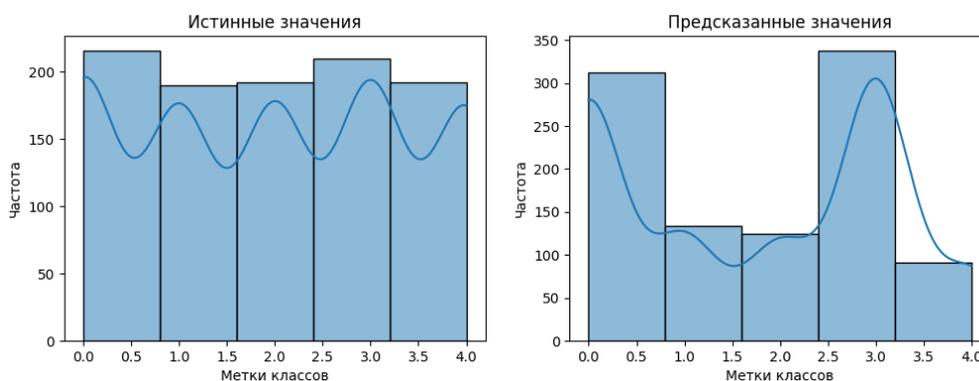


Рисунок 8 – Сравнение распределения истинных и предсказанных меток классов модели KNN

Таким образом, модель CNN оказалась наиболее подходящей среди всех рассмотренных моделей.

Анализ матрицы ошибок [20] для модели CNN также позволяет сделать вывод о ее эффективности в классификации (рис. 9а). Диагональные элементы матрицы содержат ненулевые значения, указывая на правильную классификацию примеров в каждом классе.

Отсутствие ненулевых значений вне диагонали свидетельствует об отсутствии ошибок классификации между классами, подтверждая, что модель верно определяет принадлежность примеров к соответствующим классам.

Матрица ошибок для модели LSTM выявила ее сложности в классификации (рис. 9б). Множество примеров не попадает в соответствующие классы, преимущественно предсказывая один класс, в то время как реальные данные относятся к другим. Модель многослойного персептрона (MLP) продемонстрировала высокую производительность в классификации (рис. 9в). Матрица ошибок, представленная выше, показывает, что большинство примеров были правильно классифицированы, и на диагонали матрицы присутствуют высокие значения, что указывает на правильную классификацию.

Матрица ошибок для модели KNN указывает на ее проблемы с классификацией разных классов (рис. 9г). Она часто ошибочно предсказывает примеры, как принадлежащие к одному классу, что приводит к значительным значениям вне главной диагонали матрицы [19].

Важно отметить наличие шума в данных, поскольку это может оказать значительное влияние на процесс обучения моделей и результаты классификации. Шум в данных представляет собой случайные или нежелательные изменения в значениях признаков, которые могут внести путаницу и искажения в анализ данных и моделирование. Например, вероятность переобучения увеличивается в случае наличия шума. Шум снижает количество полезной информации в данных, что может снизить их обобщающую способность. Также он может усложнить интерпретацию результатов и понимание важных признаков, так как модели могут учесть незначимые переменные.

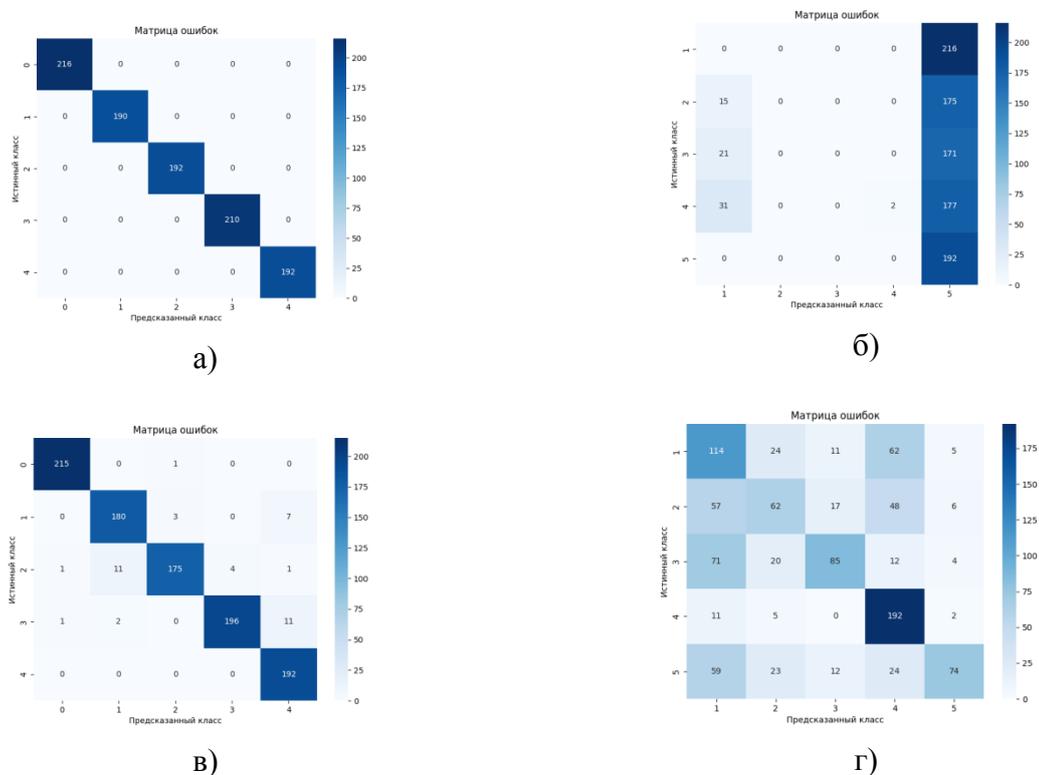


Рисунок 9 – Тепловые карты матрицы ошибок: а) модель 1 Convolutional Neural Network (CNN), б) модель 2 Long Short-Term Memory (LSTM), в) модель 3 Multilayer Perceptron (MLP), г) модель 4 «k-Nearest Neighbors (KNN)

Эксперименты с моделью CNN показали ее высокую точность в классификации горных пород. Модель способна успешно обобщать и выявлять закономерности в данных (рис. 10), позволяя, таким образом, автоматизировать процесс анализа и классификации горных пород, что экономит время и ресурсы и увеличивает точность результатов.

Другие рассмотренные модели также имеют способность справляться с этой задачей, но требуют больших затрат времени на обучение, подготовку и очистку данных, настройку параметров, что делает процесс трудоемким и длительным.

Из представленного анализа результатов следует, что CNN модель готова к последующему этапу тестирования на новых данных, лишенных шумов и не участвовавших в процессе обучения. Этот этап тестирования на новых данных без шумов является важным шагом для оценки способности модели к обобщению. Это поможет определить, насколько успешно модель способна применять свои знания и навыки к реальным данным, которые могут отличаться от данных, использованных в процессе обучения. Также процесс тестирования поможет выявить ее сильные и слабые стороны и при необходимости улучшить ее параметры. Такой итеративный процесс создаст более надежную и эффективную модель.

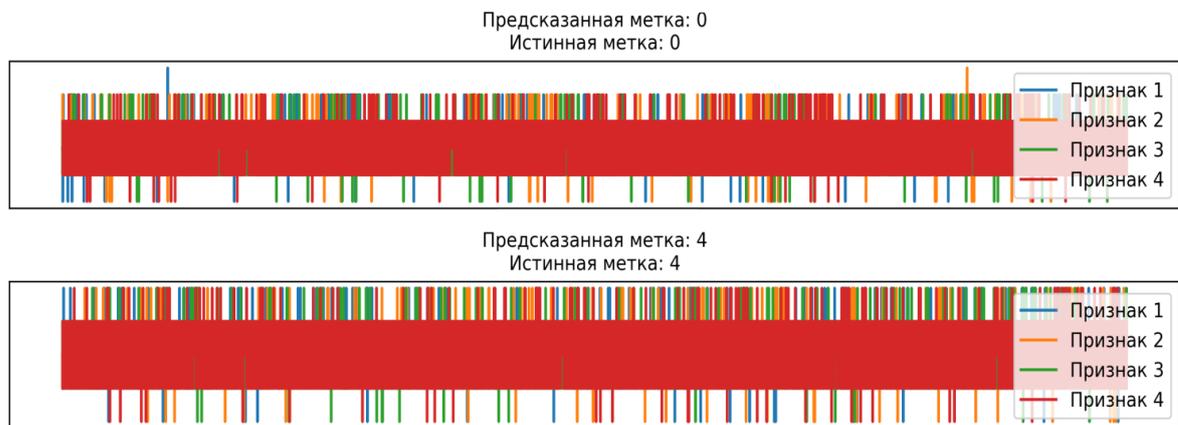


Рисунок 10 – Примеры прогнозирования модели CNN после обучения

Заключение. Таким образом, модели машинного обучения, такие как CNN, MLP, LSTM и KNN, демонстрируют свою способность к классификации и анализу горных пород на основе временных данных. Особенностью данных является наличие шума и изменчивость во времени, что делает задачу классификации более сложной. Рассмотренные модели могут быть использованы для автоматизации анализа геоматериалов, что имеет большое значение в контексте геологических исследований. При этом важно подчеркнуть, что выбор модели зависит от конкретных задач и требований, и его следует осуществлять обоснованно, учитывая особенности анализа.

Однако, как следует из исследования, модель CNN способна наилучшим образом извлекать признаки из данных и является наиболее перспективной из рассмотренных моделей: она демонстрирует высокую точность как на обучающих, так и на валидационных данных, что говорит о её лучшей способности к анализу и классификации. Эта модель может успешно применяться для анализа и классификации горных пород на реальных данных, в особенности при наличии аномальных характеристик в них. В дальнейшем можно рассмотреть совместное обучение с учетом аномалий, если они представляют важную информацию, и в случае, если аномальные события могут повлечь за собой серьезные последствия, модель может быть настроена на их обнаружение. Полученные результаты говорят о потенциале модели в различных областях применения, включая геологические

исследования и горнодобывающую промышленность. Дальнейшие исследования могут быть направлены на усовершенствование модели и её адаптацию к различным геологическим задачам с целью расширения области её применения.

Интеграция сенсорных технологий и методов машинного обучения для целей геоэкологического анализа обещает сократить время, уменьшить ресурсозатраты и повысить точность результатов. Это особенно актуально для мониторинга геоэкологической среды, выявления изменений и реагирования на экологические угрозы и природные катастрофы.

Литература

1. Taye, M.M. Understanding of Machine Learning with Deep Learning: Architectures, Workflow, Applications and Future Directions. *Computers* 2023, 12, 91. <https://doi.org/10.3390/computers12050091>
2. Модели прогноза уровня загрязнения атмосферного воздуха г. Бишкек / Н. М. Лыченко, Л. И. Великанова, С. Н. Верзунов, А. В. Сорокова // Вестник Кыргызско-Российского Славянского университета. – 2021. – Т. 21, № 4. – С. 87–95. – EDN IRIZPF.
3. М. В. Венгерова, А. С. Венгеров. Минералы и горные породы : учеб. пособие — Екатеринбург : Изд-во Урал. ун-та, 2017 — 132 с.
4. Верзунов, С. Н. Концепция интеллектуальной системы геоэкологического мониторинга / С. Н. Верзунов // Проблемы автоматизации и управления. – 2023. – № 2(47). – С. 91–108. – EDN ZXUMLR.
5. Haselsteiner, E., Pfurtscheller, G.: Using time-dependent neural net works for EEG classification. *IEEE Transactions on Rehabilitation Engineering* 8(4), 457–463 (2000)
6. Касимова, А. У. Разработка программно-определяемой радиосистемы для измерения физических свойств геоматериалов / А. У. Касимова, С. Н. Верзунов // Проблемы автоматизации и управления. – 2023. – № 1(46). – С. 59–64. – EDN WJNBQZ.
7. Верзунов, С. Н. Способ оптимизации конструктивных параметров ячеек-резонаторов микрополосковых антенн на основе интеллектуального анализа данных / С. Н. Верзунов // Электротехнические системы и комплексы. – 2022. – № 3(56). – С. 54– 64. – DOI 10.18503/2311-8318-2022-3(56)-54-64. – EDN GBBNJP.
8. The free & open software radio ecosystem // URL: <https://www.gnuradio.org/> (дата обращения 11.11.2023)
9. HackRF One – Обзор лучшего SDR: Возможности // URL: <https://cisoclub.ru/hackrf-one-obzor-luchshego-sdr-vozmozhnosti-chto-eto-kak-polzovatsya-undermind/> (дата обращения 29.09.2023).
10. https://ru.wikipedia.org/wiki/Синфазная_и_квадратурная_составляющие_сигнала#/media/Файл:In-phase_and_quadrature_components_of_angle_modulation.gif (дата обращения 11.09.2023)
11. LeCun Y., Bottou L., Bengio Y., Haffne P. Gradient-Based Learning Applied to Document Recognition // *Proc. IEEE*. – 1998. – P.59-67.
12. Wei Chen, Ke Shi, Multi-scale Attention Convolutional Neural Network for time series classification, *Neural Networks*, Volume 136, 2021, Pages 126-140, ISSN 0893-6080, <https://doi.org/10.1016/j.neunet.2021.01.001>
13. Wang, J., Li, S., Ji, W. et al. A T-CNN time series classification method based on Gram matrix. *Sci Rep* 12, 15731 (2022). <https://doi.org/10.1038/s41598-022-19758-5>

14. Understanding LSTM Networks. – URL: <http://colah.github.io/posts/2015-08-Understanding-LSTMs/> (дата обращения 14.09.2023).
15. В чем разница между глубоким обучением и нейронными сетями // URL: <https://aws.amazon.com/ru/compare/the-difference-between-deep-learning-and-neural-networks/> (дата обращения 14.09.2023).
16. Multi-Layer Perceptron Learning in Tensorflow // URL: <https://www.geeksforgeeks.org/multi-layer-perceptron-learning-in-tensorflow/> (дата обращения 29.09.2023).
17. k-Nearest Neighbors // URL: <https://www.geeksforgeeks.org/k-nearest-neighbours/> (дата обращения 29.09.2023).
18. Франсуа Шолле, Эрик Нильсон, Стэн Байлесчи, Шэнкуинг Цэй Java Script для глубокого обучения: Tensor Flow.js. – СПб.: Питер, 2021. – 576 с.:ил. — (Серия «Библиотека программиста»).
19. Траск Эндрю. Грожаем глубокое обучение. — СПб.: Питер, 2019. — 352 с.: ил. — (Серия «Библиотека программиста»).
20. Оценка классификатора (точность, полнота, F-мера). - URL: <http://bazhenov.me/blog/2012/07/21/classification-performance-evaluation.html>. (дата обращения 29.09.2023).