

Евразийский Союз Ученых. Серия: междисциплинарный

Ежемесячный научный журнал

№ 1 (121)/2026 Том 1

ГЛАВНЫЙ РЕДАКТОР

Макаровский Денис Анатольевич

AuthorID: 559173

Заведующий кафедрой организационного управления Института прикладного анализа поведения и психолого-социальных технологий, практикующий психолог, специалист в сфере управления образованием.

РЕДАКЦИОННАЯ КОЛЛЕГИЯ

• **Штерензон Вера Анатольевна**

AuthorID: 660374

Уральский федеральный университет им. первого Президента России Б.Н. Ельцина, Институт новых материалов и технологий (Екатеринбург), кандидат технических наук

• **Зыков Сергей Арленович**

AuthorID: 9574

Институт физики металлов им. М.Н. Михеева УрО РАН, Отдел теоретической и математической физики, Лаборатория теории нелинейных явлений (Екатеринбург), кандидат физ-мат. наук

• **Дронсейко Виталий Витальевич**

AuthorID: 1051220

Московский автомобильно-дорожный государственный технический университет (МАДИ), Кафедра "Организация и безопасность движения" (Москва), кандидат технических наук

• **Синьковский Антон Владимирович**

AuthorID: 806157

Московский государственный технологический университет "Станкин", кафедра информационной безопасности (Москва), кандидат технических наук

• **Карпенко Юрий Дмитриевич**

AuthorID: 338912

Центр стратегического планирования и управления медико-биологическими рисками здоровью ФМБА, Лаборатория эколого-гигиенической оценки отходов (Москва), доктор биологических наук.

• **Ильясов Олег Рашитович**

AuthorID: 331592

Уральский государственный университет путей сообщения, кафедра техносферной безопасности (Екатеринбург), доктор биологических наук

• **Глазунов Николай Геннадьевич**

AuthorID: 297931

Самарский государственный социально-педагогический университет, кафедра философии, истории и теории мировой культуры (Москва), кандидат философских наук

• **Штерензон Владимир Александрович**

AuthorID: 762704

Уральский федеральный университет им. первого Президента России Б.Н. Ельцина, Институт фундаментального образования, Кафедра теоретической механики (Екатеринбург), кандидат технических наук

Статьи, поступающие в редакцию, рецензируются. За достоверность сведений, изложенных в статьях, ответственность несут авторы. Мнение редакции может не совпадать с мнением авторов материалов. При перепечатке ссылка на журнал обязательна. Материалы публикуются в авторской редакции.

Журнал зарегистрирован Федеральной службой по надзору в сфере связи, информационных технологий и массовых коммуникаций.

Художник: Валегин Арсений Петрович
Верстка: Курпатова Ирина Александровна

Адрес редакции:
198320, Санкт-Петербург, Город Красное Село, ул. Геологическая, д. 44, к. 1, литера А
E-mail: info@euroasia-science.ru ;
www.euroasia-science.ru

Учредитель и издатель ООО «Логика+»
Тираж 1000 экз.

СОДЕРЖАНИЕ

СЕЛЬСКОХОЗЯЙСТВЕННЫЕ НАУКИ

Фартуков В.А., Зборовская М.И.

СРАВНИТЕЛЬНАЯ ОЦЕНКА ТРАДИЦИОННЫХ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ ПРИ КЛАССИФИКАЦИИ
ГИДРОХИМИЧЕСКИХ ДАННЫХ..... 4

СЕЛЬСКОХОЗЯЙСТВЕННЫЕ НАУКИ

УДК 004.8:628.1

СРАВНИТЕЛЬНАЯ ОЦЕНКА ТРАДИЦИОННЫХ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ ПРИ КЛАССИФИКАЦИИ ГИДРОХИМИЧЕСКИХ ДАННЫХ

*Фартуков В.А.¹, Зборовская М.И.¹**¹ФГБОУ ВО РГАУ-МСХА имени К.А. Тимирязева, Институт природообустройства имени А.Н. Костякова. Россия, 127434, г. Москва, ул. Тимирязевская, 49*

COMPARATIVE EVALUATION OF TRADITIONAL MACHINE LEARNING METHODS IN HYDROCHEMICAL DATA CLASSIFICATION

*V.A. Fartukov¹, M.I. Zborovskaya¹**¹FSBEI HE RGAU-MSHA named after K.A. Timiryazev, Institute of Environmental Management named after A.N. Kostyakova. Russia, 127434, Moscow, st. Timiryazevskaya, 49*

АННОТАЦИЯ

Представлены результаты сравнительного анализа классических алгоритмов машинного обучения для решения задачи бинарной классификации в гидрохимии. Исследование направлено на разработку эффективных и интерпретируемых методов автоматизированной обработки многопараметрических данных экологического мониторинга водных ресурсов. В работе реализован полный аналитический цикл, включающий разведочный анализ, предобработку данных, обучение и валидацию моделей на основе дерева решений, метода случайного леса и градиентного бустинга. Дополнительно проведено автоматизированное моделирование с использованием библиотеки PyCaret для построения и оптимизации ансамблевых классификаторов.

Экспериментальные результаты показали, что метод случайного леса обеспечивает наивысшее значение прецизионности (0,6975), в то время как ансамблевая модель, сформированная средствами PyCaret, достигает оптимального баланса между точностью и полнотой (Accuracy = 0,6098). Анализ важности признаков выявил ведущую роль водородного показателя (pH) в процессе классификации, что коррелирует с фундаментальными положениями гидрохимии. Разработанная методология служит основой для создания систем поддержки принятия решений в области оперативного контроля качества водных ресурсов. Результаты исследования имеют практическую значимость и могут быть применены при разработке программных компонентов для систем экологического мониторинга.

ABSTRACT

This paper presents the results of a comparative analysis of classical machine learning algorithms for solving a binary classification problem in hydrochemistry. The study aims to develop effective and interpretable methods for automated processing of multiparameter data from environmental monitoring of water resources. The paper implements a full analytical cycle, including exploratory analysis, data preprocessing, training, and validation of models based on a decision tree, random forest, and gradient boosting. Additionally, automated modeling was conducted using the PyCaret library for constructing and optimizing ensemble classifiers.

Experimental results showed that the random forest method provides the highest precision (0.6975), while the ensemble model generated by PyCaret achieves an optimal balance between accuracy and recall (Accuracy = 0.6098). Feature importance analysis revealed the leading role of the hydrogen ion (pH) in the classification process, which correlates with the fundamental principles of hydrochemistry. The developed methodology serves as the basis for creating decision support systems for operational water quality monitoring. The research results have practical significance and can be applied in the development of software components for environmental monitoring systems.

Ключевые слова: машинное обучение, бинарная классификация, качество воды, гидрохимические параметры, случайный лес, градиентный бустинг, дерево решений, предобработка данных, важность признаков.

Keywords: machine learning, binary classification, water quality, hydro chemical parameters, random forest, gradient boosting, decision tree, data preprocessing, feature importance.

Введение

Эффективный контроль качества водных ресурсов представляет собой одну из ключевых задач в контексте обеспечения экологической безопасности и устойчивого развития [1]. Гидрохимические показатели воды являются интегральными индикаторами ее состояния и

определяют возможности использования в различных отраслях, включая агропромышленный комплекс [2]. Традиционные методы лабораторного анализа, несмотря на высокую достоверность, характеризуются значительными временными и материальными затратами, что

затрудняет их применение для оперативного реагирования [3].

Современные технологии сбора данных, такие как распределенные сенсорные сети, позволяют получать большие объемы информации в режиме, близком к реальному времени [4]. Однако обработка таких многомерных данных требует применения автоматизированных аналитических методов. Классические алгоритмы машинного обучения, обладающие высокой степенью интерпретируемости, сравнительно низкими вычислительными требованиями и устойчивостью на данных ограниченного объема, представляются перспективным инструментом для построения систем диагностики [5].

Задача оценки состояния водной среды может быть сформулирована как задача бинарной классификации, где на вход алгоритма подается вектор физико-химических характеристик, а результатом является отнесение пробы к категории «норма» или «отклонение». Для решения задач подобного типа широко используются алгоритмы, основанные на деревьях решений и их ансамблях, доказавшие свою эффективность на практике [6].

Целью исследования является сравнительный анализ производительности классических алгоритмов машинного обучения для задачи бинарной классификации состояния водной среды по гидрохимическим показателям.

Для достижения поставленной цели были определены следующие задачи:

1. Провести разведочный анализ исходного набора данных, включая оценку полноты, анализ распределений и выявление аномальных значений.
2. Выполнить комплексную предобработку данных: восстановление (импутация) пропущенных значений, нормализацию признаков и формирование обучающей и тестовой выборок.
3. Обучить и валидировать модели, построенные на основе трех алгоритмов: дерева решений, случайного леса и градиентного бустинга.
4. Применить инструмент автоматизированного машинного обучения PyCaret для построения и оптимизации ансамблевой модели.
5. Провести сравнительную оценку моделей по стандартным метрикам классификации и определить наиболее информативные признаки.

Материалы и методы исследования

Описание набора данных

В исследовании использовался анонимизированный набор данных, содержащий 3276 записей о гидрохимических показателях водной среды. Каждая запись описывается десятью атрибутами: девятью независимыми физико-химическими признаками и одной целевой бинарной переменной (табл. 1).

Таблица 1.

Описание признаков в исходном наборе данных

№	Признак	Описание	Единица измерения	Тип данных
1	pH	Водородный показатель	–	Непрерывный
2	Hardness	Общая жесткость	мг-экв/л	Непрерывный
3	Solids	Суммарное содержание растворенных веществ (TDS)	ppm	Непрерывный
4	Chloramines	Концентрация хлораминов	ppm	Непрерывный
5	Sulfate	Концентрация сульфат-ионов	мг/л	Непрерывный
6	Conductivity	Удельная электропроводность	мкСм/см	Непрерывный
7	Organic carbon	Содержание органического углерода	ppm	Непрерывный
8	Trihalomethanes	Концентрация тригалометанов	ppb	Непрерывный
9	Turbidity	Мутность	NTU	Непрерывный
10	Potability	Целевая переменная (0 – отклонение, 1 – норма)	–	Категориальный (бинарный)

Целевой признак *Potability* является бинарной меткой, отражающей соответствие комплексной оценки состояния воды нормативным критериям.

Разведочный анализ данных (Exploratory Data Analysis, EDA)

Анализ выполнялся с использованием библиотек языка Python: *pandas* для обработки табличных данных, *numpy* для численных вычислений, *matplotlib* и *seaborn* для визуализации [7]. Первичный анализ структуры данных показал наличие пропущенных значений в трех признаках:

pH (14,99%), Sulfate (23,84%), Trihalomethanes (4,95%). Были рассчитаны основные описательные статистики (среднее, стандартное отклонение, минимум, максимум, квартили) для всех непрерывных признаков. Близость медианы и среднего арифметического для большинства переменных указывает на отсутствие выраженной асимметрии распределений.

Для визуальной оценки разброса данных и выявления выбросов были построены диаграммы размаха (boxplot) [рис. 1].

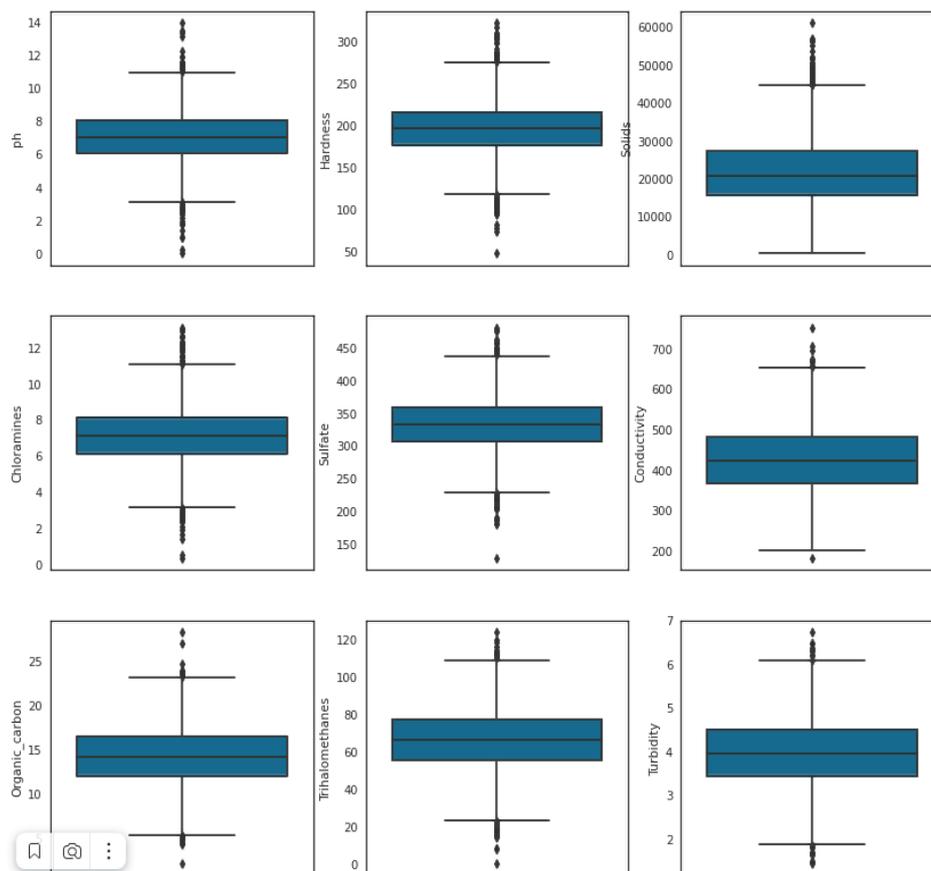


Рисунок 1 – Диаграммы размаха (boxplot) для независимых признаков

Значительные аномалии, требующие исключения из набора данных, обнаружены не были. Анализ распределения целевой переменной выявил дисбаланс классов: 61% образцов отнесены к классу «0» (отклонение) и 39% – к классу «1» (норма). Данный фактор был учтен при построении и валидации моделей.

Для оценки линейных взаимосвязей между независимыми переменными была построена

корреляционная матрица [рис. 2]. Максимальные значения коэффициента корреляции Пирсона не превышали 0,20, что свидетельствует об отсутствии сильной линейной зависимости и позволяет использовать все признаки в моделировании без риска возникновения мультиколлинеарности [8].

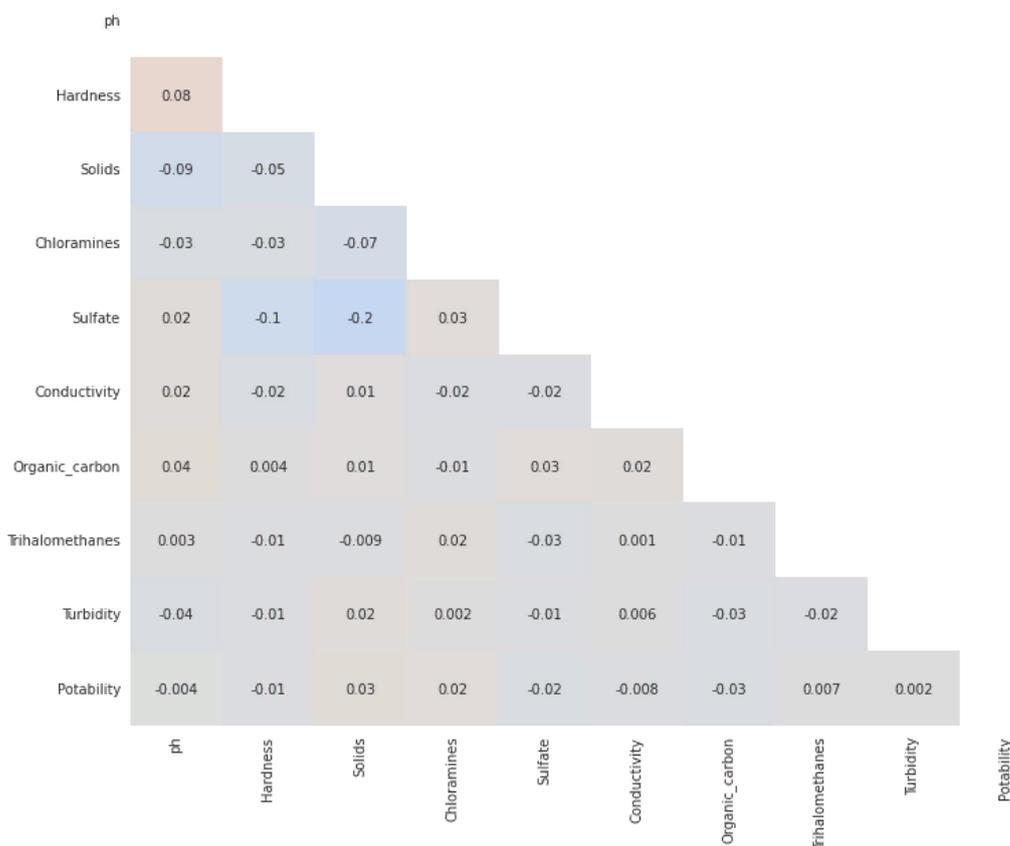


Рисунок 2 – Корреляционная матрица признаков

Предобработка данных

1. **Обработка пропущенных значений:** Для всех признаков, содержащих пропуски, была применена стратегия импутации средним арифметическим значением, рассчитанным по соответствующему столбцу. Данный метод выбран ввиду близости распределений признаков к симметричным.

2. **Разделение на выборки:** После очистки набор данных был разделен на матрицу признаков (X) и вектор целевой переменной (y). С использованием функции `train_test_split` библиотеки `scikit-learn` [9] данные были разделены на обучающую (80%) и тестовую (20%) выборки. Для обеспечения воспроизводимости результатов параметр случайного состояния (`random_state`) был зафиксирован.

3. **Масштабирование признаков:** Для приведения всех числовых признаков к единому диапазону и улучшения сходимости алгоритмов было применено Min-Max масштабирование. Параметры масштабирования (минимум и максимум) рассчитывались исключительно на обучающей выборке, после чего применялись к тестовой выборке для предотвращения «утечки данных».

Алгоритмы машинного обучения и методика оценки

Для решения задачи бинарной классификации были выбраны и реализованы следующие

классические алгоритмы, хорошо зарекомендовавшие себя на практике:

1. **Дерево решений (Decision Tree Classifier, DTC):** Простой и интерпретируемый алгоритм, строящий модель в виде древовидной структуры. Для предотвращения переобучения было установлено ограничение на максимальную глубину дерева (`max_depth=3`) [10].

2. **Случайный лес (Random Forest Classifier, RF):** Ансамблевый метод, основанный на построении множества решающих деревьев на различных подвыборках данных и агрегации их результатов. Использована стандартная реализация из библиотеки `scikit-learn` [11].

3. **Градиентный бустинг (Gradient Boosting Classifier, GBC):** Мощный ансамблевый метод, последовательно строящий деревья, каждое из которых корректирует ошибки предыдущих. Модель была настроена со следующими параметрами: количество деревьев (`n_estimators=100`), темп обучения (`learning_rate=1,0`), максимальная глубина деревьев (`max_depth=3`) [12].

4. **Автоматизированное моделирование с PyCaret:** Для сравнения с результатами ручного конструирования моделей был использован фреймворк `PyCaret` [13], автоматизирующий процессы предобработки, выбора модели и настройки гиперпараметров. В настройках была активирована техника SMOTE для устранения дисбаланса классов. Были автоматически созданы и

протестированы модели Extra Trees и Random Forest, а также их ансамбль (блендинг).

Метрики оценки: Для количественного сравнения моделей использовались стандартные метрики классификации [14]:

- **Accuracy (Точность):** Доля верно классифицированных объектов среди всех объектов выборки.

- **Precision (Прецизионность):** Доля истинно положительных прогнозов среди всех объектов, которые модель отнесла к положительному классу.

- **Recall (Полнота):** Доля истинно положительных прогнозов среди всех объектов, фактически принадлежащих положительному классу.

- **F1-score (F1-мера):** Гармоническое среднее между Precision и Recall, полезная метрика при несбалансированных классах.

- **Матрица ошибок (Confusion Matrix):** Таблица, наглядно отображающая количество истинно положительных (TP), ложно положительных (FP), истинно отрицательных (TN) и ложно отрицательных (FN) прогнозов.

Результаты

Результаты классификации классическими алгоритмами

Сравнение моделей дерева решений и случайного леса по метрике Precision показало результаты, представленные в таблице 2.

Таблица 2.

Сравнение Precision для моделей Дерева Решений и Случайного Леса

Алгоритм	Precision
Дерево решений (DTC, max_depth=3)	0,7119
Случайный лес (RF)	0,6975

Модель градиентного бустинга была оценена по расширенному набору метрик на тестовой выборке. Общая точность (Accuracy) составила 0,5808. Анализ метрик по классам показал, что модель лучше справляется с идентификацией

класса «0» (отклонение), для которого значения Precision и Recall оказались выше.

Матрица ошибок для модели случайного леса представлена на рисунке 3.

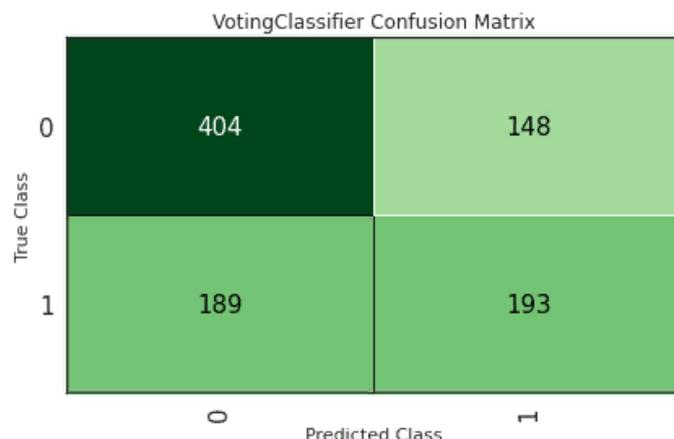


Рисунок 3 – Матрица ошибок модели Random Forest

Результаты автоматизированного моделирования с PyCaret

В результате работы с PyCaret была создана и оптимизирована ансамблевая модель (Voting

Classifier) на основе алгоритмов Extra Trees и Random Forest. Результаты 10-кратной перекрестной проверки данной модели на обучающих данных представлены в таблице 3.

Таблица 3.

Метрики ансамблевой модели PyCaret по результатам кросс-валидации

Метрика	Среднее значение	Стандартное отклонение
Accuracy	0,6428	± 0,0294
AUC-ROC	0,6709	± 0,0482
Recall	0,4578	± 0,0484
Precision	0,5454	± 0,0482
F1-score	0,4969	± 0,0440
Карра	0,2235	± 0,0640
MCC	0,2260	± 0,0649

Анализ важности признаков (Feature Importance), выполненный средствами PyCaret

[рис. 4], однозначно определил **водородный показатель (pH)** как наиболее значимый фактор

для принятия решения моделью. Это согласуется с фундаментальными принципами гидрохимии, где рН является ключевым интегральным параметром,

влияющим на химические и биологические процессы в водной среде [15].

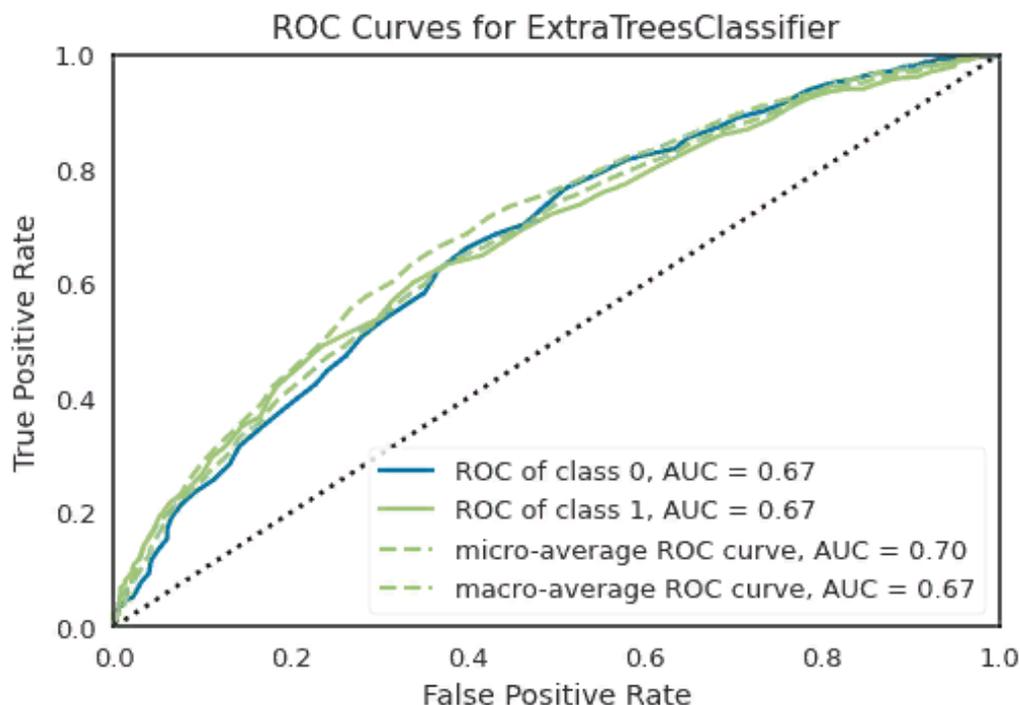


Рисунок 4 – Важность признаков в ансамблевой модели PyCaret

После завершения обучения на всем тренировочном наборе финальная модель была протестирована на предварительно

отложенной выборке (5% данных). Итоговые метрики представлены в таблице 4.

Таблица 4.

Финальные метрики ансамблевой модели PyCaret на отложенной выборке

Метрика	Значение
Model	Voting Classifier
Accuracy	0,6098
AUC	0,6279
Recall	0,5273
Precision	0,4328
F1-score	0,4754
Kappa	0,1695
MCC	0,1716

Обсуждение

Сводные результаты применения различных классических подходов представлены в таблице 5 для сравнительного анализа.

Таблица 5.

Сравнительный анализ эффективности классических алгоритмов					
Подход / Алгоритм	Ключевая метрика (Precision)	Accuracy	F1-score	Преимущества	Недостатки / Наблюдения
Дерево решений	0,7119	–	–	Высокая интерпретируемость, скорость работы	Потенциальная склонность к переобучению
Случайный лес	0,6975	–	–	Устойчивость, возможность оценки важности признаков	Повышенная вычислительная сложность по сравнению с одиночным деревом
Градиентный бустинг	0,52 (для класса 1)	0,5808	0,46 (для класса 1)	Высокий потенциал точности после тщательной настройки	Требует тонкой настройки гиперпараметров, длительное время обучения
Ансамбль PyCaret	0,4328	0,6098	0,4754	Автоматизация полного цикла, встроенные методы борьбы с дисбалансом	Меньшая прозрачность и контролируемость процесса построения модели

1. **Эффективность алгоритмов.** Наивысшее значение Precision продемонстрировало дерево решений с ограниченной глубиной. Однако данный результат требует осторожной интерпретации, поскольку может быть следствием специфики конкретного разбиения данных. Метод случайного леса, как более устойчивый ансамблевый алгоритм, показал сопоставимый результат (0,6975). Ансамблевая модель, созданная с помощью PyCaret и оптимизированная для сбалансированной точности с использованием SMOTE, достигла наилучших значений Accuracy (0,6098) и F1-меры (0,4754), что указывает на ее эффективность в условиях дисбаланса классов.

2. **Значимость признаков.** Единодушное определение признака pH как наиболее важного всеми ансамблевыми методами (Random Forest, PyCaret) является научно обоснованным и значимым результатом. Водородный показатель регламентируется всеми основными стандартами качества воды и служит ключевым индикатором ее состояния [16]. Данный вывод подтверждает адекватность выбранных алгоритмов и корректность проведенного анализа с точки зрения предметной области.

3. **Влияние дисбаланса данных.** Наличие дисбаланса классов (61% на 39%) оказало заметное влияние на результаты, особенно на метрику Recall для миноритарного класса («норма»). Модели, не учитывавшие дисбаланс явным образом (DTC, RF, GBC), показали склонность к смещению в сторону мажоритарного класса. Использование техники SMOTE в рамках PyCaret позволило улучшить баланс между Precision и Recall, что отразилось в более высоком значении F1-меры.

4. **Практическая применимость.** С точки зрения потенциального внедрения в систему поддержки принятия решений для задач экологического мониторинга, модель на

основе **случайного леса** представляется оптимальным компромиссным решением. Она сочетает в себе высокую предсказательную способность, устойчивость к переобучению, возможность анализа важности признаков (что критически важно для объяснения результатов специалистам) и приемлемую вычислительную эффективность. Инструмент автоматизированного машинного обучения PyCaret может быть рекомендован для этапа быстрого прототипирования и поиска базового решения.

Заключение

В ходе исследования был выполнен полный цикл работ по построению и сравнительному анализу классических алгоритмов машинного обучения для задачи бинарной классификации состояния водной среды по физико-химическим параметрам.

Основные результаты и выводы:

1. Разработана и апробирована методика предобработки гидрохимических данных, включающая обработку пропусков, масштабирование признаков и корректное разделение на обучающую и тестовую выборки.

2. Проведено обучение и оценка ряда классических алгоритмов: дерева решений, случайного леса, градиентного бустинга, а также ансамблевой модели, созданной с использованием фреймворка автоматизированного машинного обучения PyCaret.

3. Установлено, что метод случайного леса демонстрирует высокую и стабильную предсказательную точность (Precision = 0,6975) и может быть рекомендован как наиболее сбалансированное решение, учитывающее точность, интерпретируемость и вычислительные затраты.

4. Автоматизированная ансамблевая модель PyCaret показала наилучшую сбалансированную

точность (Accuracy = 0,6098) и F1-меру (0,4754) благодаря применению методов компенсации дисбаланса классов.

5. Ключевым научно обоснованным результатом является идентификация водородного показателя (**pH**) как наиболее значимого признака для классификации, что подтверждает соответствие результатов моделирования фундаментальным гидрохимическим закономерностям.

6. Подтверждено существенное влияние дисбаланса классов в данных на метрики классификации, что указывает на необходимость обязательного учета данного фактора и применения соответствующих корректирующих техник при построении промышленных аналитических систем.

Перспективы дальнейших исследований связаны со следующими направлениями:

- Формирование более сбалансированных и репрезентативных наборов данных для повышения надежности моделей.
- Углубленная настройка гиперпараметров моделей, в частности градиентного бустинга, с применением современных методов байесовской оптимизации.
- Разработка архитектуры системы, поддерживающей периодическое дообучение моделей на актуальных данных.
- Интеграция наиболее эффективной из полученных моделей в прототип программного модуля для системы мониторинга качества водных ресурсов, снабженного специализированным пользовательским интерфейсом.

Проведенная работа подтверждает практическую значимость и высокий потенциал классических, интерпретируемых алгоритмов машинного обучения для создания эффективных инструментов автоматизированного анализа и контроля состояния водной среды.

Список литературы

1. Food and Agriculture Organization of the United Nations (FAO). The State of the World's Land and Water Resources for Food and Agriculture (SOLAW) – Managing Systems at Risk. Rome: FAO, 2011. 308 p.
2. Ayers R.S., Westcot D.W. Water Quality for Agriculture. FAO Irrigation and Drainage Paper 29. Rev. 1. Rome: FAO, 1985. 174 p.
3. World Health Organization (WHO). Guidelines for Drinking-water Quality: Fourth Edition Incorporating the First Addendum. Geneva: WHO, 2017. 631 p.
4. Gubbi J., Buyya R., Marusic S., Palaniswami M. Internet of Things (IoT): A vision, architectural elements, and future directions // Future Generation Computer Systems. 2013. Vol. 29, № 7. P. 1645–1660. DOI: 10.1016/j.future.2013.01.010

5. Liakos K.G., Busato P., Moshou D., Pearson S., Bochtis D. Machine Learning in Agriculture: A Review // Sensors. 2018. Vol. 18, № 8. Art. 2674. 29 p. DOI: 10.3390/s18082674

6. Hastie T., Tibshirani R., Friedman J. The Elements of Statistical Learning: Data Mining, Inference, and Prediction. 2nd ed. New York: Springer, 2009. 745 p. DOI: 10.1007/978-0-387-84858-7

7. McKinney W. Data Structures for Statistical Computing in Python // Proceedings of the 9th Python in Science Conference (SciPy 2010). 2010. P. 56–61. DOI: 10.25080/Majora-92bf1922-00a

8. James G., Witten D., Hastie T., Tibshirani R. An Introduction to Statistical Learning: with Applications in R. New York: Springer, 2013. 440 p. DOI: 10.1007/978-1-4614-7138-7

9. Pedregosa F., Varoquaux G., Gramfort A. et al. Scikit-learn: Machine Learning in Python // Journal of Machine Learning Research. 2011. Vol. 12. P. 2825–2830.

10. Quinlan J.R. Induction of Decision Trees // Machine Learning. 1986. Vol. 1, № 1. P. 81–106. DOI: 10.1007/BF00116251

11. Breiman L. Random Forests // Machine Learning. 2001. Vol. 45, № 1. P. 5–32. DOI: 10.1023/A:1010933404324

12. Friedman J.H. Greedy Function Approximation: A Gradient Boosting Machine // The Annals of Statistics. 2001. Vol. 29, № 5. P. 1189–1232. DOI: 10.1214/aos/1013203451

13. Ali M. PyCaret: An Open Source, Low-Code Machine Learning Library in Python // Journal of Open Source Software. 2020. Vol. 5, № 53. Art. 2603. DOI: 10.21105/joss.02603

14. Sokolova M., Lapalme G. A systematic analysis of performance measures for classification tasks // Information Processing & Management. 2009. Vol. 45, № 4. P. 427–437. DOI: 10.1016/j.ipm.2009.03.002

15. Chapman D. (ed.). Water Quality Assessments: A Guide to the Use of Biota, Sediments and Water in Environmental Monitoring. 2nd ed. London: E & FN Spon, 1996. 651 p.

16. Eaton A.D., Clesceri L.S., Rice E.W., Greenberg A.E. (eds.). Standard Methods for the Examination of Water and Wastewater. 21st ed. Washington, DC: American Public Health Association (APHA), American Water Works Association (AWWA), Water Environment Federation (WEF), 2005.

Евразийский Союз Ученых. Серия: междисциплинарный

Ежемесячный научный журнал

№ 1 (121)/2026 Том 1

ГЛАВНЫЙ РЕДАКТОР

Макаровский Денис Анатольевич

AuthorID: 559173

Заведующий кафедрой организационного управления Института прикладного анализа поведения и психолого-социальных технологий, практикующий психолог, специалист в сфере управления образованием.

РЕДАКЦИОННАЯ КОЛЛЕГИЯ

• **Штерензон Вера Анатольевна**

AuthorID: 660374

Уральский федеральный университет им. первого Президента России Б.Н. Ельцина, Институт новых материалов и технологий (Екатеринбург), кандидат технических наук

• **Зыков Сергей Арленович**

AuthorID: 9574

Институт физики металлов им. М.Н. Михеева УрО РАН, Отдел теоретической и математической физики, Лаборатория теории нелинейных явлений (Екатеринбург), кандидат физ-мат. наук

• **Дронсейко Виталий Витальевич**

AuthorID: 1051220

Московский автомобильно-дорожный государственный технический университет (МАДИ), Кафедра "Организация и безопасность движения" (Москва), кандидат технических наук

• **Синьковский Антон Владимирович**

AuthorID: 806157

Московский государственный технологический университет "Станкин", кафедра информационной безопасности (Москва), кандидат технических наук

• **Карпенко Юрий Дмитриевич**

AuthorID: 338912

Центр стратегического планирования и управления медико-биологическими рисками здоровью ФМБА, Лаборатория эколого-гигиенической оценки отходов (Москва), доктор биологических наук.

• **Ильясов Олег Рашитович**

AuthorID: 331592

Уральский государственный университет путей сообщения, кафедра техносферной безопасности (Екатеринбург), доктор биологических наук

• **Глазунов Николай Геннадьевич**

AuthorID: 297931

Самарский государственный социально-педагогический университет, кафедра философии, истории и теории мировой культуры (Москва), кандидат философских наук

• **Штерензон Владимир Александрович**

AuthorID: 762704

Уральский федеральный университет им. первого Президента России Б.Н. Ельцина, Институт фундаментального образования, Кафедра теоретической механики (Екатеринбург), кандидат технических наук

Статьи, поступающие в редакцию, рецензируются. За достоверность сведений, изложенных в статьях, ответственность несут авторы. Мнение редакции может не совпадать с мнением авторов материалов. При перепечатке ссылка на журнал обязательна. Материалы публикуются в авторской редакции.

Журнал зарегистрирован Федеральной службой по надзору в сфере связи, информационных технологий и массовых коммуникаций.

Художник: Валегин Арсений Петрович
Верстка: Курпатова Ирина Александровна

Адрес редакции:
198320, Санкт-Петербург, Город Красное Село, ул. Геологическая, д. 44, к. 1, литера А
E-mail: info@euroasia-science.ru ;
www.euroasia-science.ru

Учредитель и издатель ООО «Логика+»
Тираж 1000 экз.