

ТЕХНОСФЕРНАЯ БЕЗОПАСНОСТЬ, ЭКОЛОГИЯ ЖИВЫХ СИСТЕМ И РАЦИОНАЛЬНОЕ ПРИРОДОПОЛЬЗОВАНИЕ

УДК 004.8:614.8

DOI 10.37468/2307-1400-2026-1-78-89

Сравнительный анализ архитектур классического и глубокого машинного обучения в задаче прогнозирования природных пожаров

*Гончаров Андрей Сергеевич*¹*Балобанов Андрей Александрович*¹*Матвеев Александр Владимирович*¹

¹ Санкт-Петербургский университет Государственной противопожарной службы МЧС России имени Героя Российской Федерации генерала армии Е.Н. Зиничева, Санкт-Петербург, Россия

Аннотация

В статье рассматривается задача вероятностного прогнозирования возникновения природных пожаров с упреждением прогноза в 24 часа и 7 суток по данным наземного метеорологического наблюдения и спутникового мониторинга. Сформировано признаковое пространство, состоящее из лаговых метеорологических, экспоненциально взвешенных средних, календарных и спутниковых признаков. Для решения задачи сравнивалась модель градиентного бустинга (CatBoost), как представителя классического машинного обучения, и нейронная сеть рекуррентного типа (LSTM), как представитель архитектур глубокого обучения. Качество моделей оценивалось по стандартным метрикам ROC-AUC, PR-AUC, F1, Precision и Recall. Статистическая устойчивость оценивалась с помощью бустрэп-анализа с построением 95% доверительных интервалов. Для дополнительной оценки выполнена калибровка вероятностей с помощью изотонической регрессии и масштабирование по Платту (Platt Scaling), проведен анализ сезонных показателей качества. Проведено исследование интерпретируемости моделей с помощью SHAP-анализа для CatBoost и метода атрибуции (Integrated Gradient) для LSTM. Получено, что CatBoost обеспечивает более сбалансированное качество прогноза и показывает более высокую чувствительность, но уступает по точности и надежности вероятностных оценок.

Ключевые слова: природные пожары, машинное обучение, CatBoost, LSTM, прогнозирование пожаров.

Введение

В условиях глобальных климатических изменений, роста антропогенной нагрузки на природные экосистемы и увеличения частоты экстремальных погодных явлений проблема природных пожаров приобретает особую актуальность [1, 2]. Особую значимость данная проблема приобретает в контексте обеспечения национальной безопасности государства. Масштабные природные пожары способны создавать угрозу жизни и здоровью граждан, приводить к уничтожению объектов критической инфраструктуры, нарушению функционирования транспортных и энергетических систем, а также вызывать значительный экономический ущерб. В ряде случаев последствия крупных пожаров затрагивают вопросы

продовольственной, экологической и энергетической безопасности регионов. Кроме того, задымление атмосферы и выбросы парниковых газов оказывают влияние на качество воздуха и климатические процессы, что усиливает долгосрочные риски для общества и экономики.

Эффективное противодействие природным пожарам невозможно без создания современных систем мониторинга и прогнозирования, обеспечивающих своевременное выявление факторов пожарной опасности и поддержку принятия управленческих решений [3, 4].

Традиционные подходы прогнозирования опираются на эмпирические и физико-метеорологические методы, но их возможностей часто недостаточно для описания сложных нелинейных зависимостей, возникающих между факторами, определяющими возникновение пожара [5, 6]. Развитие технологий дистанционного зондирования Земли, геоинформационных систем, метеорологических наблюдений и сенсорных сетей привело к накоплению значительных объемов пространственно-временных данных, содержащих информацию о состоянии природной среды. Это создает предпосылки для широкого применения методов искусственного интеллекта и машинного обучения при решении задач оценки пожарной опасности [7, 8] и прогнозирования возникновения пожаров.

Традиционные методы машинного обучения, включая деревья решений, случайные леса, метод опорных векторов и ансамблевые алгоритмы, продемонстрировали высокую эффективность при анализе структурированных данных и построении прогностических моделей [9]. Вместе с тем стремительное развитие глубокого обучения открыло новые возможности для автоматического извлечения сложных нелинейных зависимостей из многомерных данных, включая спутниковые изображения, временные ряды метеорологических наблюдений и геопространственную информацию. Архитектуры глубоких нейронных сетей, такие как сверточные и рекуррентные нейронные сети, позволяют учитывать пространственные и временные закономерности, оказывающие влияние на возникновение и распространение природных пожаров [10].

Несмотря на значительное количество исследований в данной области, вопрос сравнительной эффективности классических и глубоких моделей машинного обучения остается актуальным. Различия в требованиях к объему данных, вычислительным ресурсам, интерпретируемости результатов и точности прогнозирования требуют комплексного анализа преимуществ и ограничений различных подходов применительно к задачам прогнозирования природных пожаров.

Градиентный бустинг показывает высокую эффективность на табличных данных и хорошо работает с признаками разного типа [11-13]. Архитектуры нейронных сетей рекуррентного типа, в частности LSTM (Long Short-Term Memory), способны учитывать временную структуру процесса и длительные зависимости, благодаря своей внутренней памяти [14, 15]. Но для прикладных задач, к которой собственно и относится прогнозирование ЧС природного характера и природных пожаров в целом, важны не только точность и полнота прогноза, но и статистическая устойчивость, сезонная стабильности и интерпретируемость результатов моделей.

Цель настоящего исследования заключается в сравнительном анализе моделей градиентного бустинга и LSTM для вероятностного прогнозирования возникновения природных пожаров на горизонтах 24 часа и 7 суток, а также исследовании статистической устойчивости, сезонной неоднородности ошибок, качества калибровки вероятностей и интерпретируемости моделей.

Методы исследования

В исследовании использовались два источника данных, представленные метеорологическими наблюдениями и спутниковыми данными о термических точках. Метеорологические данные включали в себя суточные значения температуры, относительной влажности, скорости и направления ветра, осадков и атмосферного давления. Выборка была собрана за период с 2019 по 2024 год, ее объем составил 140 тысяч наблюдений. Спутниковые данные были получены из информационной системы NASA FIRMS MODIS [16], они содержали

координаты термических точек, их яркость, мощность, показатели достоверности и технические характеристики измерений. Выборка была собрана за тот же период что и метеорологические данные, объем наблюдений был более 1 млн записей.

Объединение этих источников позволило одновременно учитывать условия возникновения пожара и фактическую активность. Пространственная привязка термических точек осуществлялась к ближайшим, доступным в открытых источниках, метеостанциям, после чего строилась единая последовательность признаков и целевых переменных.

Сама задача формулировалась как бинарная классификация события с вероятностным выходом. Для каждой даты и метеорологической станции модель должна была оценивать вероятность возникновения нового пожара в заданном горизонте упреждения. Рассматривались горизонты в 24 часа (оперативный прогноз) и 7 суток (краткосрочный прогноз).

Перед обучением данные подвергались предобработке, в которой проводилась очистка, проверка на корректность и полноту. Некорректные данные и пропущенные значения восстанавливались или удалялись в зависимости от характера ошибок. Для части переменных использовались логарифмические преобразования. Все лаговые признаки, скользящие средние и экспоненциально взвешенные характеристики вычислялись только по прошлым значениям.

Признаковое пространство формировалось следующим образом: был составлен вектор входных признаков, который включал в себя метеорологические параметры, их лаговые значения, экспоненциально взвешенные средние, календарные признаки, признаки, отражающие пожарную обстановку (включали пространственные и категориальные значения).

Для всех метеорологических параметров вычислялись лаги на 1,2,3,7 и 14 дней, а также экспоненциально взвешенное скользящее среднее (EWMA) с различными размерами окон. Такой набор признаков позволят дать моделям градиентного бустинга память, что дает возможность учитывать краткосрочную и долгосрочную инерцию погодных процессов. Сезонность была закодирована через синусо-косинусное представление дня года и месяца, что обеспечивает корректную обработку цикличности явлений. Признаки пожарной обстановки включали показатели наличия пожара в предыдущие дни, длительности текущего события, время с последнего пожара и другие индикаторы, отражающие пространственно-временную динамику процесса. Категориальные признаки содержали сведения о регионе и метеорологических станциях для учета локальных климатических различий, а также характеристик насаждений.

Объединенная выборка строго разделялась по времени. Данные за 2019-2022 гг. использовались в качестве обучающей выборки, 2023 г. – для валидации и подбора порогов, данные 2024 г. использовались в качестве итогового тестирования. Такое разделение соответствует реальному сценарию применения моделей, когда прогноз строится на основе исторических данных и оценивается на будущем периоде, не участвовавшем в обучении. Для моделей градиентного бустинга (CatBoost) дополнительно применялась кросс-валидация при подборе гиперпараметров, это было реализовано с целью уменьшения риска переобучения и получения более устойчивых оценок качества [17]. Для LSTM был использован стандартный вариант, описанный выше.

На начальном этапе исследования для горизонта в 24 часа рассматривались три алгоритма градиентного бустинга: CatBoost, XGBoost и LightGBM. Гиперпараметры подбирались по ограниченной сетке с использованием кросс-валидации, в результате лучший результат показал CatBoost, который был принят как основная модель для 24 часов и послужил архитектурой и для 7 дневного горизонта. Гиперпараметры представлены в таблице 1.

Таблица 1 – Сетка подбора гиперпараметров для оперативной модели

Фреймворк	Итерации	Глубина деревьев	Скорость обучения	Баланс классов
CatBoost	100,200	4,6	0.05,0.1	{0:1,1:1.5},{0:1,1:2}
XGBoost	100,200	4,6	0.05,0.1	w, 1.2w
LightGBM	100,200	4,6	0.05,0.1	balanced

Для 7-ми дневного упреждения CatBoost обучался с увеличенным до 1000 числом итераций и глубиной деревьев 7, с регуляризацией и учетом дисбаланса классов. Дополнительно была реализована модель LSTM, она принимала последовательности данных длиной 60 дней с 51 признаком на шаге. Архитектура следующая: слой LSTM с 64 скрытыми нейронами, полносвязный слой из 32 нейронов и выходной слой с одним нейроном. Общее число параметров модели составило 32065. Обучение LSTM проводилось на GPU с 6 гигабайтами видеопамати, гиперпараметры были следующими: размер батча 64, скорость обучения $3e-4$, dropout 0.5 и ограничением градиента 1.0. Ранняя остановка применялась по качеству на валидационной выборке.

Объемы выборок для моделей были следующими: для CatBoost итоговый набор данных включал 9896 образцов в обучающей выборке, 2459 образцов валидационной выборки и 2729 тестовой. Для LSTM объемы выборок составили 11844, 2542 и 2846 образцов соответственно. Различие в объеме обусловлено способом формирования входов, CatBoost обучался на чисто табличных признаках, тогда как LSTM использовала тензоры содержащие последовательности длиной 60 дней. Доля положительных исходов 45%, что указывает на умеренный дисбаланс классов. Это означает, что задача, хотя и не является сильно несбалансированной, но все равно требует использования пороговой оптимизации и метрик чувствительным к редким событиям. Объясняется такой дисбаланс тем, что модели ищут не конкретный день из окна в 7 дней, а фиксируют наличие пожара в окне в целом.

Подбор порога бинаризации для каждой модели осуществлялся по максимуму F1-меры на валидационной выборке. Для CatBoost оптимальный порог 0.40, для LSTM – 0.35. Благодаря этому подходу получилось согласовать вероятностный выход моделей с практической задачей разделения на пожароопасные и безопасные дни.

Качество моделей оценивали по стандартным метрикам:

1. ROC-AUC (площадь по ROC-кривой, которая характеризует способность модели различать классы по всем возможным порогам);
2. PR-AUC (площадь под кривой Precision-Recall, которая показывает качество распознавания положительного класса);
3. Precision (доля истинных природных пожаров среди всех предсказанных);
4. Recall (доля предсказанных природных пожаров среди всех фактически произошедших);
5. F1 (гармоническое среднее Precision и Recall).

Наиболее важными для задачи прогнозирования природных пожаров являются метрики F1 и Recall, поскольку пропуск опасного события важнее ложноположительного срабатывания.

Для оценки статистической устойчивости метрик использовался бутстрэп-анализ [18]. Из тестовой выборки многократно формировались выборки с возвращением, для которых вычислялись основные метрики, описанные выше. Всего было выполнено 1000 повторов. Доверительные интервалы строились с уровнем доверительной вероятности равным 0.95.

Для повышения практической значимости и применимости прогнозов проводилась калибровка вероятностей. Калибровка важна для систем прогнозирования, так как модель должна выдавать не только бинарный класс, но и интерпретируемую вероятность риска.

Результаты исследования

На горизонте прогнозирования в 24 часа лучше всего показал себя CatBoost, который обеспечил высокий уровень F1 и показал устойчивое поведение на временной валидации. LightGBM и XGBoost показали близкие к CatBoost результаты, но несколько уступили по основным метрикам, на основе этого для краткосрочного прогноза был выбран CatBoost, а также было принято решение сразу использовать этот метод градиентного бустинга для горизонта в 7 суток.

С упреждением в 7 суток CatBoost и LSTM показали близкие по смыслу, но разные по характеру результаты (Рисунок 1). Лучшие показатели по F1 дал CatBoost, а LSTM показала

более высокую чувствительность и чаще находила положительные события, при этом с большим, чем у бустинга, количеством ложных срабатываний.




Рисунок 1 – Сравнение качества моделей на тестовой выборке

На тестовой выборке 2024 года модели показали результаты, представленные в Таблице 2.

Таблица 2 – Метрики качества моделей на тестовой выборке

Метрика	CatBoost	LSTM
F1	0.75	0.73
Recall	0.84	0.90
Precision	0.68	0.65
ROC-AUC	0.84	0.81

Результаты из Таблицы 2 подтверждают, что CatBoost на текущем объеме выборок является более сбалансированной моделью, тогда как LSTM позволяет обнаруживать максимальное количество опасных дней.

Говоря о статистической устойчивости приведем результаты бутстрэп-анализа, которые представлены в Таблице 3.

Таблица 3 – Доверительные интервалы метрик моделей

Метрика	CatBoost	LSTM
F1	0.730–0.766	0.712–0.748
Recall	0.834–0.877	0.844–0.879
Precision	0.641–0.688	0.610–0.657
ROC-AUC	0.828–0.859	0.794–0.824

Как видно из Таблицы 3 бутстрэп-анализ подтверждает устойчивость выводов, полученных по точечным метрикам. Главный вывод здесь заключается в том, что это факт наличия частичных перекрытий интервалов по метрике Recall. Это говорит о близости возможностей моделей

в обнаружении положительных случаев. Делая общий вывод из устойчивости и результатов на тестовой выборке можно сказать, что различие между моделями не только в точечной оценке, но и в характере ошибок. Бустинг работает более стабильно и избирательно, а LSTM направлена на более высокую чувствительность.

Анализ метрик и статистической устойчивости, конечно, является важным, но необходимо оценить результаты и с точки зрения воспроизводимости реальных процессов моделями. Для этого проведен анализ полноты по месяцам, он показал ярко выраженную сезонность качества прогноза, что напрямую согласуется с пожароопасным периодом на территории РФ. При этом в признаковое пространство в явном виде не были включены сведения о границах и наличие в принципе пожароопасного периода, модели сами восстановили его по косвенным данным.

Из Рисунка 2 явно видно, что модели стабильно работали в пожароопасный период с марта по октябрь, в зимние месяцы и ноябре значения Recall были нестабильным, что и логично, в связи с чем были убраны из визуализации. Это объясняется отсутствием положительных примеров в выше перечисленные месяцы. Также видно, что CatBoost демонстрировал более равномерное поведение, а LSTM выдавала отдельные пики. Это говорит о важности фактора сезонной динамики для оценки интерпретации моделей.




Рисунок 2 – Recall по месяцам на тестовой выборке

Для оценки интерпретации модели CatBoost был использован SHAP-анализ [19, 20] глобальной важности признаков, который показал следующие результаты (Рисунок 3).

Анализ показал, что наибольшее влияние оказывали экспоненциально сглаженные температурные признаки, влажность, календарные признаки, а также показатели пожарной обстановки и региональные признаки.

Для LSTM применялся метод атрибуции (Integrated Gradients). Он позволяет оценить вклад каждого входного признака в итоговое предсказание и является одним из наиболее корректных подходов к интерпретации нейронных сетей [21, 22].

Как видно из Рисунка 4, сеть чувствительна к показателям пожарной обстановки, экспоненциально взвешенного скользящего среднего температуры (EWMA), влажности и осадков.




Рисунок 3 – Глобальная важность признаков по SHAP




Рисунок 4 – Тепловая карта важности признаков LSTM

Результаты SHAP-анализа и метода атрибуции в целом совпадают, обе модели выделяют корректные признаки в качестве основных предикторов риска, что повышает уровень доверия к их выводам, так как они соответствуют реальным процессам формирования природных пожаров.

Однако необходимо максимально удостовериться в правильности получаемых прогнозов. Для этого была проведена калибровка вероятностей, она оценивалась с помощью метрики ECE (ожидаемой ошибки калибровки) [23]. Для CatBoost метрика ECE была близка к общепринятому значению в 0.05, но все же несколько больше него. Для модели LSTM применили масштабирование по Платту (Platt Scaling) [24], так как значение ECE до калибровки было 0.195, что много больше 0.05, и при этих условиях изотоническая регрессия не дала бы результатов и просто переобучилась. После проведения калибровки значения ECE для моделей стали меньше 0.05, что говорит о высокой надежности получаемых прогнозов.

Как видно из Рисунка 5, после калибровки модели показывают высокую надежность вероятностных прогнозов, особенно это заметно в диапазоне вероятностей больше 0.5 за красной пунктирной линией, которая представляет собой порог, после прохождения которого видно, что модели близки к идеальной калибровке, а также это означает, что можно доверять высоким значениям вероятностей, полученных от моделей.




Рисунок 5 – Калибровочные кривые моделей на тестовой выборке

Заключение

В ходе исследования было проведено прямое сравнение моделей CatBoost и LSTM для вероятностного прогнозирования возникновения природных пожаров на горизонтах в 24 часа и 7 суток. Сформировано признаковое пространство, включающее в себя метеорологические, спутниковые, календарные и ретроспективные характеристики. Для оценки качества моделей применялись стандартные метрики, а также доверительные интервалы и анализ калибровки вероятностей.

Экспериментально получено, что CatBoost является наиболее сбалансированной моделью. Сезонный анализ и интерпретации через SHAP-анализ и метода атрибуции (Integrated Gradients) показали, что модели соответствуют реальным физическим процессам, а надежность прогнозов подтверждена анализом калибровки вероятностей.

Полученные результаты на используемых в работе объемах выборках позволяют рекомендовать CatBoost как основную модель для прогнозирования природных пожаров на основе табличных данных, однако необходимо понимать, что при больших объемах выборок LSTM покажет более высокие результаты, а также формирование признакового пространства для них несколько проще ввиду наличия восторженной памяти.

Список литературы

1. Константинов А.В., Морковина В.В. Лесные пожары как наиболее значимая угроза экономической безопасности лесного сектора // Актуальные направления научных исследований XXI века: теория и практика. – 2016. – Т. 4, № 2(22). – С. 319-325. – EDN UOWSNE.
2. Белов А.Н. Лесные пожары как угроза пожарной безопасности: современное состояние и предупреждение // Вестник экономики, управления и права. – 2023. – Т. 16, № 1. – С. 62-70. – EDN DHJWFB.
3. Медведев Д.В., Матвеев А.В. Алгоритмы интеллектуальной поддержки принятия управленческих решений при угрозах лесных пожаров // Научно-аналитический журнал "Вестник Санкт-Петербургского университета Государственной противопожарной службы МЧС России". – 2025. – № 2. – С. 35-48. – DOI 10.61260/2218-130X-2025-2-35-48. – EDN OKGHLE.
4. Медведев Д.В., Матвеев А.В. Информационная модель поддержки принятия решений по реагированию на ландшафтные пожары // Сибирский пожарно-спасательный вестник. – 2025. – № 1(36). – С. 117-125. – DOI 10.34987/vestnik.sibpsa.2025.22.36.011. – EDN PKSBTBTR.
5. Prokhorenkova L. et al. CatBoost: unbiased boosting with categorical features // Advances in Neural Information Processing Systems. – 2018. – Vol. 31.
6. Матвеев А.В., Богданова Е.М. Классификация методов прогнозирования чрезвычайных ситуаций // Национальная безопасность и стратегическое планирование. – 2018. – № 4(24). – С. 61-70. – EDN YTPZYL.
7. Матвеев А.В., Медведев Д.В., Смирнов А.С. Возможности применения технологий искусственного интеллекта для повышения эффективности управления в чрезвычайных ситуациях // Информатизация и связь. – 2025. – № 4. – С. 98-111. – DOI 10.34219/2078-8320-2025-16-4-98-111. – EDN KGTJCQ.
8. Медведев Д.В., Матвеев А.В., Смирнов А.С. Применение модели логистической регрессии при принятии решений по определению количества привлекаемых сил на ликвидацию лесных пожаров // Пожаровзрывобезопасность. – 2024. – Т. 33, № 4. – С. 84-96. – DOI 10.22227/0869-7493.2024.33.04.84-96. – EDN MJLVTY.
9. Медведев Д.В., Матвеев А.В. Возможности применения системы интеллектуальной поддержки принятия решений при реагировании на угрозы лесных пожаров // Технологии техносферной безопасности. – 2025. – № 3(109). – С. 74-89. – DOI 10.25257/TTS.2025.3.109.74-89. – EDN GZXXSU.
10. Родионов А.М., Иванов С.А. Анализ современных моделей и информационных систем при прогнозировании и мониторинге лесных пожаров // Экономика. Информатика. – 2023. – Т. 50, № 4. – С. 913-923. – DOI 10.52575/2712-746X-2023-50-4-913-923. – EDN QYFBQJ.
11. Chen T., Guestrin C. XGBoost: A Scalable Tree Boosting System // Proc. 22nd ACM SIGKDD. – 2016. – P. 785-794. – DOI 10.1145/2939672.2939785
12. Ke G. et al. LightGBM: A Highly Efficient Gradient Boosting Decision Tree // Advances in Neural Information Processing Systems. – 2017. – Vol. 30. – P. 3146-3154.
13. Raparathi M. et al. Implementation and Performance Comparison of Gradient Boosting Algorithms for Tabular Data Classification // International Conference on Deep Learning and Visual Artificial Intelligence. – Singapore : Springer Nature Singapore, 2024. – P. 461-479. DOI 10.1007/978-981-97-4533-3_36
14. Prapas I. et al. Deep Learning Methods for Daily Wildfire Danger Forecasting // arXiv preprint arXiv:2111.02736. – 2021. – DOI 10.48550/arXiv.2111.02736
15. Ku C.Y., Liu C.Y. Predictive modeling of fire incidence using deep neural networks // Fire. – 2024. – V. 7. – No 4. – P. 136. – DOI 10.3390/fire7040136
16. Liu Z. et al. NASA global satellite and model data products and services for tropical meteorology and climatology // Remote Sensing. – 2020. – V. 12. – No 17. – P. 2821. – DOI 10.3390/rs12172821
17. Adler A.I., Painsky A. Feature importance in gradient boosting trees with cross-validation feature selection // Entropy. – 2022. – V. 24. – No 5. – P. 687. – DOI 10.3390/e24050687
18. Sakai T. Evaluating evaluation metrics based on the bootstrap // Proceedings of the 29th annual international ACM SIGIR conference on Research and development in information retrieval. – 2006. – P. 525-532. – DOI 10.1145/1148170.1148261

19. *Sundararajan M., Taly A., Yan Q.* Axiomatic attribution for deep networks // Proceedings of the 34th International Conference on Machine Learning. – 2017. – P. 3319-3328.
20. *Матвеев А.В.* Сравнительный анализ методов интерпретируемости моделей искусственного интеллекта в процессах принятия решений // Современные наукоемкие технологии. – 2026. – № 5. – С. 131-138. – DOI 10.17513/snt.40785. – EDN KJORY.
21. *Ancona M. et al.* Towards better understanding of gradient-based attribution methods for deep neural networks // arXiv preprint arXiv:1711.06104. – 2017. DOI 10.48550/arXiv.1711.06104
22. *Du M. et al.* On attribution of recurrent neural network predictions via additive decomposition // The world wide web conference. – 2019. – P. 383-393. – DOI 10.1145/3308558.3313545
23. *Posocco N., Bonnefoy A.* Estimating expected calibration errors // International conference on artificial neural networks. – Cham : Springer International Publishing, 2021. – P. 139-150. – DOI 10.1007/978-3-030-86380-7_12
24. *Raina R. et al.* Impact of platt scaling on calibration in ML-based wireless resource allocation // 2025 IEEE International Conference on Machine Learning for Communication and Networking (ICMLCN). – IEEE, 2025. – P. 1-5. – DOI 10.1109/ICMLCN64995.2025.11140554

Статья поступила в редакцию 16 февраля 2026 г.
Принята к публикации 21 марта 2026 г.

Ссылка для цитирования: Гончаров А.С., Балобанов А.А., Матвеев А.В. Сравнительный анализ архитектур классического и глубокого машинного обучения в задаче прогнозирования природных пожаров // Национальная безопасность и стратегическое планирование. 2026. № 1(53). С. 78-89. DOI: <https://doi.org/10.37468/2307-1400-2026-1-78-89>

Comparative analysis of classical and deep machine learning architectures in wildfire forecasting

*Goncharov Andrey S.*¹

*Balobanov Andrey A.*¹

*Matveev Alexander V.*¹

¹*Saint Petersburg University of the State Fire Service of the Ministry of Emergency Situations of Russia named after Hero of the Russian Federation General of the Army E.N. Zinichev, Saint Petersburg, Russia*

Abstract

This article examines the problem of probabilistic wildfire forecasting with a 24-hour and 7-day lead time based on ground-based meteorological observations and satellite monitoring. A feature space was constructed consisting of lagged meteorological, exponentially weighted average, calendar, and satellite features. To solve the problem, a gradient boosting model (CatBoost), as a representative of classical machine learning, and a recurrent neural network (LSTM), as a representative of deep learning architectures, were compared. Model performance was assessed using standard metrics such as ROC-AUC, PR-AUC, F1, Precision, and Recall. Statistical robustness was assessed using bootstrap analysis with 95% confidence intervals. For additional evaluation, probabilities were calibrated using isotonic regression and Platt scaling, and an analysis of seasonal quality indicators was conducted. A study of the interpretability of the models was conducted using SHAP analysis for CatBoost and the Integrated Gradient attribution method for LSTM. It was found that CatBoost provides a more balanced forecast quality and demonstrates higher sensitivity, but is inferior in the accuracy and reliability of probabilistic estimates.

Keywords: wildfires, machine learning, CatBoost, LSTM, fire forecasting.

References

1. *Konstantinov A.V., Morkovina V.V.* Forest fires as the most significant threat to the economic security of the forestry sector // Current areas of scientific research in the 21st century: theory and practice. – 2016. – Vol. 4, No. 2 (22). – Pp. 319-325. – EDN UOWSNE.

2. *Belov A.N.* Forest fires as a threat to fire safety: current state and prevention // *Bulletin of Economics, Management and Law*. – 2023. – Vol. 16, No. 1. – Pp. 62-70. – EDN DHJWFB.
3. *Medvedev D.V., Matveev A.V.* Algorithms for intelligent support of management decisions in the event of forest fire threats // *Scientific and analytical journal "Bulletin of the St. Petersburg University of the State Fire Service of the Ministry of Emergency Situations of Russia"*. – 2025. – No. 2. – P. 35-48. – DOI 10.61260/2218-130X-2025-2-35-48. – EDN OKGHLE.
4. *Medvedev D.V., Matveev A.V.* Information model for supporting decision-making on responding to landscape fires // *Siberian Fire and Rescue Bulletin*. – 2025. – No. 1(36). – P. 117-125. – DOI 10.34987/vestnik.sibpsa.2025.22.36.011. – EDN PKSBTBTR.
5. *Prokhorenkova L. et al.* CatBoost: unbiased boosting with categorical features // *Advances in Neural Information Processing Systems*. – 2018. – Vol. 31.
6. *Matveev A.V., Bogdanova E.M.* Classification of methods for forecasting emergency situations // *National Security and Strategic Planning*. – 2018. – No. 4 (24). – P. 61-70. – EDN YTPZYL.
7. *Matveev A.V., Medvedev D.V., Smirnov A.S.* Possibilities of applying artificial intelligence technologies to improve the efficiency of emergency management // *Informatization and Communications*. – 2025. – No. 4. – P. 98-111. – DOI 10.34219/2078-8320-2025-16-4-98-111. – EDN KGTJCQ.
8. *Medvedev D.V., Matveev A.V., Smirnov A.S.* Application of the logistic regression model in decision-making on determining the number of forces involved in extinguishing forest fires // *Fire and Explosion Safety*. – 2024. – Vol. 33, No. 4. – Pp. 84-96. – DOI 10.22227/0869-7493.2024.33.04.84-96. – EDN MJLVTY.
9. *Medvedev D.V., Matveev A.V.* Possibilities of using an intelligent decision support system in responding to forest fire threats // *Technologies of technosphere safety*. – 2025. – No. 3 (109). – Pp. 74-89. – DOI 10.25257/TTS.2025.3.109.74-89. – EDN GZXXSU.
10. *Rodionov A.M., Ivanov S.A.* Analysis of modern models and information systems in forecasting and monitoring forest fires // *Economy. Informatics*. – 2023. – Vol. 50, No. 4. – P. 913-923. – DOI 10.52575/2712-746X-2023-50-4-913-923. – EDN QYFBQJ.
11. *Chen T., Guestrin C.* XGBoost: A Scalable Tree Boosting System // *Proc. 22nd ACM SIGKDD*. – 2016. – P. 785-794. – DOI 10.1145/2939672.2939785
12. *Ke G. et al.* LightGBM: A Highly Efficient Gradient Boosting Decision Tree // *Advances in Neural Information Processing Systems*. – 2017. – Vol. 30. – P. 3146-3154.
13. *Raparthi M. et al.* Implementation and Performance Comparison of Gradient Boosting Algorithms for Tabular Data Classification // *International Conference on Deep Learning and Visual Artificial Intelligence*. – Singapore : Springer Nature Singapore, 2024. – P. 461-479. DOI 10.1007/978-981-97-4533-3_36
14. *Prapas I. et al.* Deep Learning Methods for Daily Wildfire Danger Forecasting // *arXiv preprint arXiv:2111.02736*. – 2021. – DOI 10.48550/arXiv.2111.02736
15. *Ku C.Y., Liu C.Y.* Predictive modeling of fire incidence using deep neural networks // *Fire*. – 2024. – V. 7. – No 4. – P. 136. – DOI 10.3390/fire7040136
16. *Liu Z. et al.* NASA global satellite and model data products and services for tropical meteorology and climatology // *Remote Sensing*. – 2020. – V. 12. – No 17. – P. 2821. – DOI 10.3390/rs12172821
17. *Adler A.I., Painsky A.* Feature importance in gradient boosting trees with cross-validation feature selection // *Entropy*. – 2022. – V. 24. – No 5. – P. 687. – DOI 10.3390/e24050687
18. *Sakai T.* Evaluating evaluation metrics based on the bootstrap // *Proceedings of the 29th annual international ACM SIGIR conference on Research and development in information retrieval*. – 2006. – P. 525-532. – DOI 10.1145/1148170.1148261
19. *Sundararajan M., Taly A., Yan Q.* Axiomatic attribution for deep networks // *Proceedings of the 34th International Conference on Machine Learning*. – 2017. – P. 3319-3328.
20. *Matveev A.V.* Comparative analysis of methods of interpretability of artificial intelligence models in decision-making processes // *Modern science-intensive technologies*. – 2026. – No. 5. – P. 131-138. – DOI 10.17513/snt.40785. – EDN KKJORY.
21. *Ancona M. et al.* Towards better understanding of gradient-based attribution methods for deep neural networks // *arXiv preprint arXiv:1711.06104*. – 2017. DOI 10.48550/arXiv.1711.06104
22. *Du M. et al.* On attribution of recurrent neural network predictions via additive decomposition // *The world wide web conference*. – 2019. – P. 383-393. – DOI 10.1145/3308558.3313545

23. *Posocco N., Bonnefoy A.* Estimating expected calibration errors // International conference on artificial neural networks. – Cham : Springer International Publishing, 2021. – P. 139-150. – DOI 10.1007/978-3-030-86380-7_12

24. *Raina R. et al.* Impact of platt scaling on calibration in ML-based wireless resource allocation // 2025 IEEE International Conference on Machine Learning for Communication and Networking (ICMLCN). – IEEE, 2025. – P. 1-5. – DOI 10.1109/ICMLCN64995.2025.11140554

For citation: Goncharov A.S., Balobanov A.A., Matveev A.V. Comparative analysis of classical and deep machine learning architectures in wildfire forecasting // National security and strategic planning. 2026. № 1(53). pp. 78-89. DOI: <https://doi.org/10.37468/2307-1400-2026-1-78-89>

Сведения об авторах:

Гончаров Андрей Сергеевич – кафедра системного анализа и антикризисного управления, Санкт-Петербургский университет Государственной противопожарной службы МЧС России имени Героя Российской Федерации генерала армии Е.Н. Зиничева,, г. Санкт-Петербург, Россия
e-mail: andreygoncharov04@mail.ru

Балобанов Андрей Александрович – кандидат технических наук, доцент кафедры системного анализа и антикризисного управления, Санкт-Петербургский университет Государственной противопожарной службы МЧС России имени Героя Российской Федерации генерала армии Е.Н. Зиничева, г. Санкт-Петербург, Россия
ORCID: <https://orcid.org/0000-0003-3346-8171>
SPIN-код: 3288-5595
e-mail: andrey.balobanov.92@mail.ru

Матвеев Александр Владимирович – кандидат технических наук, доцент, заведующий кафедрой прикладной математики и информационных технологий, Санкт-Петербургский университет Государственной противопожарной службы МЧС России имени Героя Российской Федерации генерала армии Е.Н. Зиничева, г. Санкт-Петербург, Россия ORCID: <https://orcid.org/0000-0002-0778-3218>
SPIN-код: 5778-8832
e-mail: fcvega_10@mail.ru

Information about authors:

Goncharov Andrey S. – Systems Analysis and Crisis Management Department, St. Petersburg University of the State Fire Service of the Ministry of Emergency Situations of Russia named after Hero of the Russian Federation, Army General E.N. Zinichev, St. Petersburg, Russia
e-mail: andreygoncharov04@mail.ru

Balobanov Andrey S. – Candidate of Technical Sciences, Associate Professor of the Systems Analysis and Crisis Management Department, St. Petersburg University of the State Fire Service of the Ministry of Emergency Situations of Russia named after Hero of the Russian Federation, Army General E.N. Zinichev, St. Petersburg, Russia
ORCID: <https://orcid.org/0000-0003-3346-8171>
SPIN: 3288-5595
e-mail: andrey.balobanov.92@mail.ru

Matveev Alexander V. – Candidate of Technical Sciences, Associate Professor, Head of the department of applied mathematics and information technologies, St. Petersburg University of the State Fire Service of the Ministry of Emergency Situations of Russia named after Hero of the Russian Federation, Army General E.N. Zinichev, St. Petersburg, Russian Federation
ORCID: <https://orcid.org/0000-0002-0778-3218>
SPIN: 5778-8832
e-mail: fcvega_10@mail.ru