

Дистанционное зондирование сред

DOI 10.66032/2221-2574-2026-1-1-5-13

УДК 621.396.67

ИССЛЕДОВАНИЕ ВЛИЯНИЯ ГОРИЗОНТА ПРОГНОЗИРОВАНИЯ НА ТОЧНОСТЬ ПРЕДСКАЗЫВАНИЯ МЕТЕОПАРАМЕТРОВ АТМОСФЕРЫ МОДЕЛЯМИ МАШИННОГО ОБУЧЕНИЯ

Матюков Максим Андреевич

аспирант ФГБОУ ВО «Владимирский Государственный университет¹ имени А.Г. и Н.Г. Столетовых».

Федосеева Елена Валерьевна

доктор технических наук, доцент, профессор кафедры радиотехники Муромского института² (филиала) ФГБОУ ВО «Владимирский Государственный университет имени А.Г. и Н.Г. Столетовых».

Ростокин Илья Николаевич

доктор технических наук, доцент, профессор кафедры управления и контроля в технических системах Муромского института² (филиала) ФГБОУ ВО «Владимирский Государственный университет имени А.Г. и Н.Г. Столетовых».

Щукин Георгий Георгиевич

доктор физико-математических наук, профессор, начальник лаборатории АО «Государственный научно-исследовательский навигационно-гидрографический институт» (АО «ГНИНГИ»)³.

¹Адрес: 600000, Российская Федерация, г. Владимир, ул. Горького, д. 87.

²Адрес: 602264, Российская Федерация, Владимирская обл., г. Муром, ул. Орловская, д. 23.

³Адрес: 199106, Российская Федерация, г. Санкт-Петербург, Кожевенная линия, д. 41.

E-mail для связи: elenafedoseeva@yandex.ru

Аннотация: В статье рассмотрены вопросы оценки точности прогнозирования метеопараметров приземного слоя атмосферы для различных моделей машинного обучения (МО) при разных значениях горизонта прогнозирования. Определены задачи и методика сравнительного анализа эффективности работы моделей на краткосрочных и сверхкраткосрочных интервалах прогноза. Выполнено обучение и тестирование ряда алгоритмов машинного обучения, включая методы регрессии, градиентный бустинг и алгоритмы деревьев, на основе данных измерений многоканальной СВЧ радиометрической системы и приземных метеонаблюдений. Предложен подход к формированию обучающих выборок с учётом временной структуры данных для различных горизонтов прогнозирования. Получены численные оценки точности прогноза — средняя абсолютная ошибка (САО), коэффициент корреляции (R), средняя квадратическая ошибка (СКО), средняя ошибка модели (СОМ) — для температуры, влажности и атмосферного давления, и сделаны выводы о применимости различных моделей в зависимости от требуемого горизонта прогноза.

Ключевые слова: машинное обучение, прогнозирование метеопараметров, горизонт прогноза, микроволновая радиометрия, нейронные сети, сравнительный анализ.

Введение

В настоящее время одним из ключевых направлений развития систем мониторинга атмосферы является совершенствование методов краткосрочного прогнозирования метеопараметров на основе данных дистанционного зондирования. Эффективное предсказание температуры, влажности, интенсивности осадков и других параметров критически важно для своевременного выяв-

ления и предупреждения опасных метеорологических явлений. Значительный потенциал для решения этой задачи демонстрируют методы машинного обучения, которые показывают высокую результативность при анализе временных рядов и выявлении сложных нелинейных зависимостей в данных измерений и значений метеопараметров атмосферы [1–3].

Дистанционное микроволновое (СВЧ) радиометрическое зондирование предоставляет интегральную информацию о состоянии атмосферы путём измерения мощности собственного радиотеплового излучения на различных частотах [4–8]. Последующее решение обратных задач позволяет восстановить пространственно-временное распределение ключевых метеопараметров. Однако точность и заблаговременность прогноза в значительной степени зависят не только от качества исходных данных и выбранной модели, но и от горизонта прогнозирования — временного интервала, на который строится предсказание.

Известно, что с увеличением горизонта прогнозирования ошибка предсказания, как правило, возрастает, но характер этого роста и его зависимость от типа используемой модели машинного обучения изучены недостаточно. Сравнительный анализ эффективности разных алгоритмов — таких, как методы регрессии и алгоритмы деревьев — при различных временных горизонтах является актуальной научно-практической задачей [9–11].

В данной работе проводится исследование влияния горизонта прогнозирования на точность предсказания метеопараметров приземного слоя атмосферы для различных моделей машинного обучения. Анализ выполняется на основе результатов измерений многоканальной СВЧ радиометрической системы и синхронных метеорологических измерений. Целью работы является сравнительная оценка результатов работы разных моделей МО в зависимости от величины горизонта прогнозирования и точности предсказания метеопараметров для задач оперативного мониторинга приземного слоя атмосферы.

Исходные данные для обучения алгоритмов МО

В качестве источника данных СВЧ радиометрии использовались измерения радиометра, установленного в городе Муром, на крыше института МИ ВлГУ [3, 8]. Период наблюдений, используемый в данной работе для разработки и тестиро-

вания моделей машинного обучения, охватывает август 2023 по декабрь 2024 года.

Основные характеристики радиометра: прибор проводит непрерывные измерения радиояркой температуры атмосферы в направлении города Нижний Новгород под углом в 45° относительно зенита в трёх частотных диапазонах с центральными частотами 4 ГГц, 10 ГГц и 22 ГГц на вертикальной и горизонтальной поляризации. Временное разрешение для формируемого массива значений яркой температуры составляет 5 минут. Точность измерений радиояркой температуры (радиометрическая чувствительность) равна 0.03–0.05 К для времени интегрирования 1 с в зависимости от канала.

В качестве данных для обучения и валидации моделей машинного обучения, прогнозирующих целевые метеопараметры, использовались данные измерений наземной метеостанции, расположенной вблизи СВЧ радиометрической системы, получаемые с периодичностью 5 минут и измеренные значения радиояркой температуры.

Измеренные значения радиояркой температуры и целевые метеопараметры, полученные с метеостанций, имеют разное временное разрешение, поэтому была выполнена синхронизация этих данных. Определяется единая временная сетка и для каждого момента времени t в этой сетке сопоставляются измеренные значения радиояркой температуры и значения целевых метеопараметров. Было задано допустимое временное окно ± 5 минут для сопоставления измерений из разных источников и сформированы временные ряды, где каждой временной метке t соответствует как набор радиометрических измерений, так и набор значений метеопараметров, относящихся к этому же моменту времени.

На основе синхронизированных данных формировался вектор входных признаков $X(t)$, который подавался на вход модели машинного обучения для прогнозирования состояния атмосферы на определённый промежуток времени, задаваемый, как горизонт прогнозирования.

Таблица 1. Сравнительная характеристика методов МО для задачи СВЧ-радиометрии

Метод	Способность к нелинейности	Устойчивость к шуму	Интерпретируемость	Требования к данным (объём)	Вычислительная сложность (обучение/предсказание)
Линейная регрессия и её вариации	Низкая	Низкая	Высокая	Низкие	Низкая / Очень низкая
Метод опорных векторов SVR	Высокая	Средняя	Низкая / Средняя	Средние	Средняя-Высокая / Низкая-Средняя
Random Forest, RF	Высокая	Высокая	Средняя	Средние	Средняя / Низкая
Градиентный бустинг GBM, XGBoost, LightGBM, CatBoost	Очень высокая	Средняя / Высокая	Низкая	Средние / Высокие	Высокая / Низкая

Выбор моделей машинного обучения

Выбор моделей был обусловлен целью сравнения эффективности алгоритмов различной сложности — от простых линейных методов до современных нелинейных подходов, способных улавливать сложные временные зависимости. Для формирования алгоритмов машинного обучения использовались программы KNIME и Orange Data Mining. Для наглядного сравнения потенциально применимых методов МО (машинного обучения) составлена сводная таблица, оценивающая их по ключевым критериям, релевантным для задачи СВЧ-радиометрии атмосферы и прогнозирования метеопараметров. К таким критериям относятся: способность моделировать нелинейные зависимости, устойчивость к шуму, интерпретируемость модели, требования к объёму данных, вычислительная сложность, возможность работы с многомерными входными данными (радиояркостные температуры на разных частотах и углах) и временными рядами.

Исходя из анализа данных таблицы 1 были отобраны модели МО, доступные в knime и orange, по три для каждой указанной программы (для $\Delta t = 5$ минут), проведено сравнение их точности между собой. Затем исходя из полученных результатов выбраны по две с лучшими параметрами, проведён повторный эксперимент для $\Delta t = 30$ минут, затем по одному алгоритму — для $\Delta t = 2$ часа. Проанализирована динамика показателей качества в зависимости от увеличения Δt и изменения сезона.

Для всесторонней оценки точности прогнозов использовались следующие общепринятые показатели качества: среднеквадратическая ошибка (СКО), средняя абсолютная ошибка (САО), средняя ошибка модели (СОМ) и коэффициент корреляции (R).

Результаты тестирования методов машинного обучения для задачи прогнозирования метеопараметров

Обучающая выборка для всех моделей МО — измеренные данные с октября 2023 до декабря 2024 года объёмом 92636 строк. Тестирующая выборка — данные измерений за 20.12.2024 объёмом 288 строк. Результаты прогноза температуры и влажности представлены в таблице 2., где t , °C — температура, φ ; % — относительная влажность воздуха.

Для сверхкраткосрочного прогноза (5 минут) лучшие результаты по прогнозированию как температуры, так и влажности показали ансамблевые алгоритмы, в частности Random Forest и Tree Ensemble из KNIME. Они демонстрируют наименьшие значения ошибок (СКО, САО) и наиболее высокий коэффициент корреляции (R).

Все модели предсказывают температуру существенно точнее, чем влажность, о чем свидетельствуют значительно меньшие ошибки и более высокий R (например, ~86% для температуры против ~70% для влажности у лучших моделей). Это указывает на более

Таблица 2. Сравнение методов МО, $\Delta t = 5$ минут, горизонт прогнозирования — 1 день

Модель	Параметр	СКО	САО	СОМ	R
Linear regression	t, °C	6,663	6,227	-3,633	79,985
	φ, %	13,720	12,075	2,780	17,339
Polynomial regression (kname)	t, °C	2,827	2,444	-0,236	82,603
	φ, %	10,570	9,073	0,978	24,543
Random forest (kname)	t, °C	1,617	1,323	0,803	85,937
	φ, %	6,589	5,501	3,527	70,173
Tree Ensemble (kname)	t, °C	1,651	1,375	0,886	87,849
	φ, %	6,729	5,656	3,445	68,734
Random forest (orange)	t, °C	1,863	1,586	0,817	77,768
	φ, %	7,074	5,746	3,100	53,302
Catboost (orange)	t, °C	2,265	1,898	0,562	74,218
	φ, %	8,228	6,992	1,383	26,697
Gradient boosted trees (orange)	t, °C	2,599	2,191	0,718	79,798
	φ, %	8,321	7,010	0,519	7,572

сложный, нелинейный характер изменений влажности.

Модели, реализованные в KNIME (Random Forest, Tree Ensemble), в целом превзошли аналоги из Orange Data Mining по точности прогноза на данном временном горизонте.

Линейная и полиномиальная регрессии показали худшие результаты, особенно для влажности, что подтверждает необходимость использования более сложных, нелинейных моделей для адекватного описания атмосферных процессов.

С увеличением горизонта прогнозирования до 30 минут и интервала прогноза до 6 дней точность всех моделей закономерно снижается (возрастают СКО и САО, уменьшается R), что соответствует ожидаемому накоплению ошибки.

Tree Ensemble (KNIME) и Random Forest (KNIME) показали также лучший результат, был получен наименьший рост ошибок и наибольшая устойчивость прогноза температуры (R ~ 86%). Для влажности их точность также осталась наивысшей, хотя коэффициент R снизился примерно вдвое по сравнению с прогнозом на 5 минут.

Модель CatBoost (Orange), которая уступала на коротком горизонте, показала сопоставимую точность с Tree Ensemble (KNIME) и Random Forest (KNIME) по температуре на тридцатиминутном горизонте, что лучше результатов Random Forest из Orange. Это говорит о том, что разные алгоритмы по-разному реагируют на увеличение горизонта прогноза.

Точность прогноза влажности для большинства моделей упала значительно сильнее,

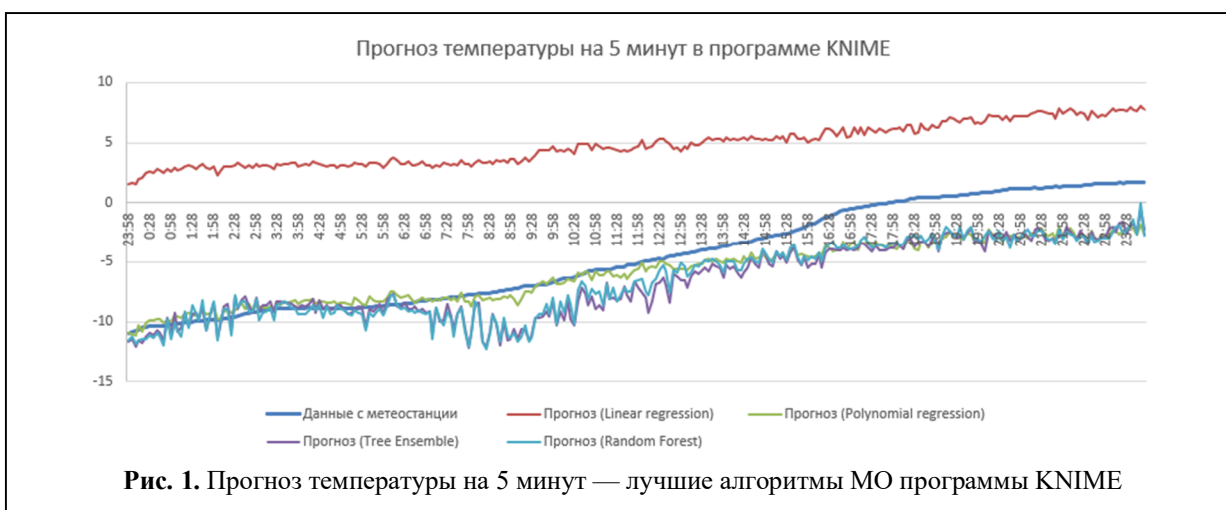


Рис. 1. Прогноз температуры на 5 минут — лучшие алгоритмы МО программы KNIME

чем температуры (R для многих моделей ниже 40%), что ещё раз подчёркивает сложность моделирования этого параметра на длительных временных горизонтах прогнозирования.

При переходе к горизонту прогнозирования в два часа наблюдается резкое снижение точности у всех оставшихся в сравнении моделей. Ошибки (СКО, САО) возрастают в несколько раз по сравнению с результатами для $\Delta t = 5$ минут.

Tree Ensemble (KNIME) показала лучшие результаты по сравнению с CatBoost (Orange) и, особенно, с линейной регрессией, которая неэффективна на таком длительном горизонте.

У всех моделей, кроме Tree Ensemble для влажности, проявилась значительная средняя ошибка модели (СОМ), причём

отрицательная для температуры. Это указывает на возникновение систематического смещения (bias) в прогнозах, когда модели начинают постоянно занижать или завышать прогнозируемые значения.

Результаты позволили сделать выводы, что для выбранного набора признаков и моделей горизонт в два часа является крайне сложным.




Рис. 2. Прогноз влажности на 5 минут — лучшие алгоритмы МО программы Orange Data Mining

Таблица 3. Сравнение методов МО, $\Delta t = 30$ минут, горизонт прогнозирования — 6 дней

Модель	Параметр	СКО	САО	СОМ	R
Linear regression	t, °C	8,230	6,913	-2,513	64,105
	φ, %	13,903	11,563	-1,617	12,887
Random forest (knime)	t, °C	3,493	2,708	0,282	85,743
	φ, %	9,452	7,683	0,082	37,199
Tree Ensemble (knime)	t, °C	3,451	2,682	0,271	86,065
	φ, %	9,430	7,612	0,257	37,195
Random forest (orange)	t, °C	4,778	3,809	1,384	39,263
	φ, %	11,122	8,395	1,466	31,410
Catboost (orange)	t, °C	3,852	2,996	0,142	84,037
	φ, %	9,779	7,768	-0,267	31,127




Рис. 3. Прогноз влажности на 30 минут — лучшие алгоритмы МО программы Knime




Рис. 4. Прогноз температуры на 30 минут — лучшие алгоритмы МО программы Orange

Даже лучшая модель (Tree Ensemble) обеспечивает коэффициент детерминации для температуры около 66%, что может быть недостаточно для высокоточных прикладных задач.

Заключение

Проведённое исследование позволило количественно оценить влияние горизонта прогнозирования на точность предсказания температуры и влажности воздуха с использованием данных СВЧ-радиометрии и различных моделей машинного обучения. Полученные результаты выявили закономерности в изменении точности прогнозов, что позволило сформулировать практические рекомендации по выбору моделей МО для решения задачи прогнозирования метеопараметров атмосферы.

Подтверждено, что с увеличением горизонта прогнозирования от 5 минут до 2 часов точ-

ность всех моделей закономерно снижается. Однако степень деградации качества сильно зависит от типа алгоритма. Например, для прогноза температуры на 5 минут лучшие модели (Random Forest, Tree Ensemble в KNIME) демонстрировали коэффициент корреляции $R > 85\%$, в то время как при прогнозе на 2 часа этот показатель для лучшей модели (Tree Ensemble) снизился до 66.4%.

На всех протестированных горизонтах прогноза ансамблевые алгоритмы (RF, градиентный бустинг) показали себя значительно эффективнее линейных методов. Так, при прогнозе температуры на 30 минут СКО линейной регрессии составила 8,23°C, в то время как СКО Tree Ensemble (KNIME) была почти в 2,5 раза ниже — 3,45°C. Это подтверждает их способность улавливать сложные нелинейные зависимости в данных.

Установлено, что прогноз температуры является существенно более надёжной задачей, чем прогноз влажности. На кратких горизонтах (5 минут) разница в точности была заметной ($R \sim 86\%$ против $\sim 70\%$), а на длительных (2 часа) — критической: для влажности коэффициент корреляции

Таблица 4. Сравнение методов МО, $\Delta t = 120$ минут, горизонт прогнозирования — 6 дней

Модель	Параметр	СКО	CAO	COM	R
Linear regression	t, °C	10,583	8,740	-7,361	49,356
	φ, %	21,580	17,986	9,679	9,887
Tree Ensemble (knime)	t, °C	5,088	4,277	-3,161	66,405
	φ, %	15,684	13,185	0,575	41,883
Catboost (orange)	t, °C	5,671	4,902	-3,844	63,197
	φ, %	18,861	16,578	1,668	39,273

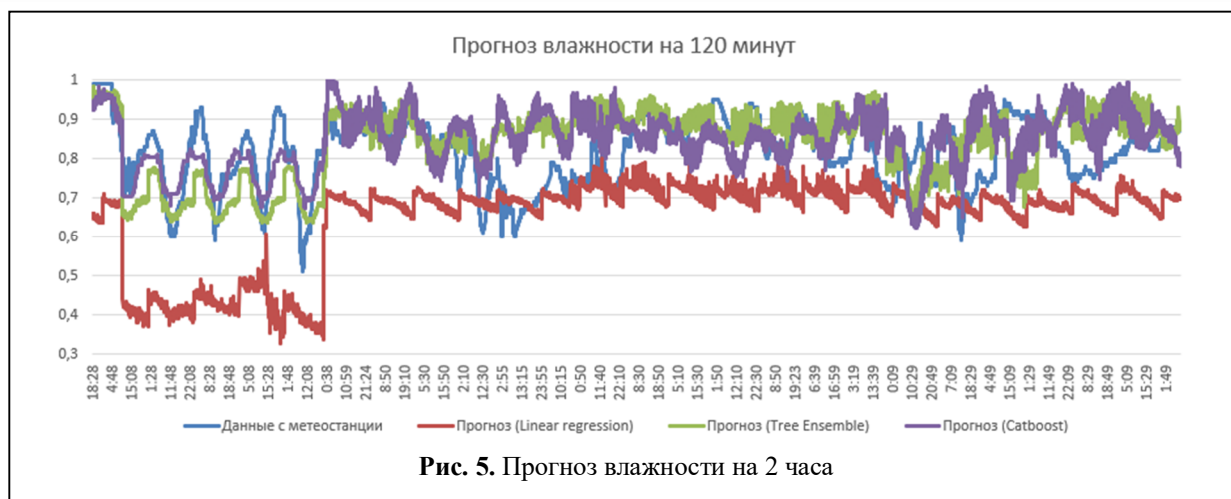


Рис. 5. Прогноз влажности на 2 часа

лучшей модели не превышал 42%, а ошибки (СКО >15%) делают прогноз практически малоприменимым для точных приложений.

Выбор модели машинного обучения в зависимости от длительности горизонта прогнозирования может быть обусловлен следующими результатами:

- для сверхкраткосрочного прогноза (5–30 минут) наилучшие результаты показали Tree Ensemble и Random Forest, реализованные в среде KNIME;

- для краткосрочного прогноза (до 2 часов) модель Tree Ensemble (KNIME) также сохранила лидерство, однако общее падение точности указывает на то, что данный горизонт является предельным для используемого подхода с прогнозом исключительно на основе мгновенных радиометрических данных;

- на горизонте 2 часа у большинства моделей проявилась значительная средняя ошибка (СОМ), особенно для температуры (до $-3,16^{\circ}\text{C}$ у Tree Ensemble), что указывает на появление систематического смещения (bias), которое необходимо учитывать и корректировать в практических применениях.

Таким образом, исследования установили,

что выбор модели машинного обучения для прогнозирования метеопараметров по данным СВЧ-радиометрии не может быть универсальным и должен жёстко привязываться к целевому горизонту прогноза. Полученные количественные критерии эффективности для разных алгоритмов являются основой для построения адаптивных систем мониторинга, где алгоритм прогнозирования будет гибко выбираться или настраиваться в зависимости от требуемой заблаговременности и точности. Для повышения точности на горизонтах свыше 30 минут необходима разработка моделей, явно учитывающих временную динамику, например, рекуррентных нейронных сетей.

Литература

1. Матюков М.А., Федосеева Е.В., Росточкин И.Н. и др. Анализ точности нейросетевого про-

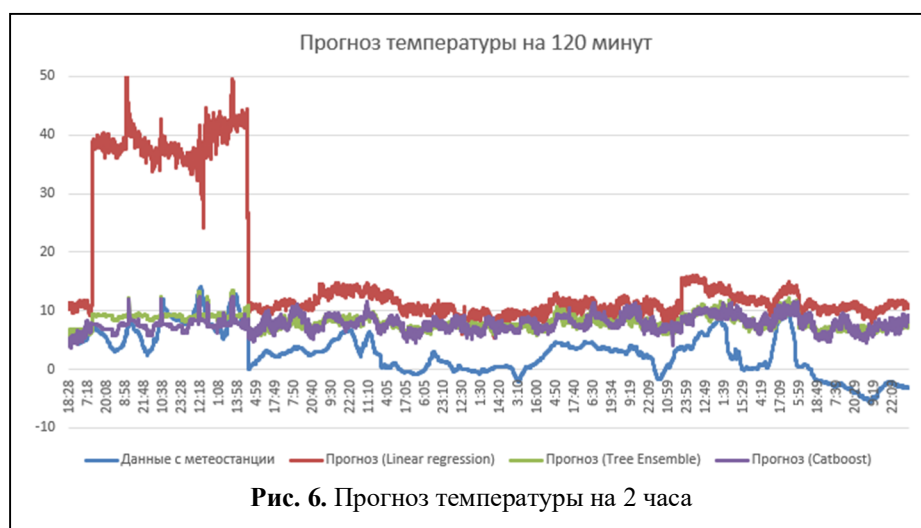


Рис. 6. Прогноз температуры на 2 часа

гнозирования метеопараметров по результатам многочастотных СВЧ радиометрических измерений атмосферы // Всероссийские открытые Армандовские чтения: Современные проблемы дистанционного зондирования, радиолокации, распространения и дифракции волн. 2024. № 1. С. 506–511.

2. Kalchbrenner N., Sønderby C. A Neural Weather Model for Eight-Hour Precipitation Forecasting [Электронный ресурс] // Google AI Blog. 2020. March 25. URL: <https://ai.googleblog.com/2020/03/a-neural-weather-model-for-eight-hour.html> (дата обращения 20.10.2025).

3. Федосеева Е.В., Ростокин И.Н., Щукин Г.Г. и др. Нейронная сеть в задачах краткосрочного прогнозирования по результатам микроволнового радиометрического зондирования атмосферы // Радиотехнические и телекоммуникационные системы. 2023. №3. С. 20–28.

4. Степаненко В.Д., Щукин Г.Г., Бобылев Л.П., Матросов С.Ю. Радиотеплолокация в метеорологии. Л.: Гидрометеиздат, 1987. 283 с.

5. Куруза Б.Г., Яковлев О.И., Данилычев М.В. Спутниковый мониторинг Земли: Микроволновая радиометрия атмосферы и поверхности. Монография. М.: Ленанд, 2016. 336 с.

6. Кадыгров Е.Н. Микроволновая радиометрия термической стратификации атмосферы. М.: ФГБУ "ЦАО", 2020. 271 с.

7. Ware R.A. A multichannel radiometric profiler of temperature, humidity, and cloud liquid // Radio Science. 2003. Vol. 38, Iss. 4. P. 8079. DOI: 10.1029/2002RS002856.

8. Щукин Г.Г., Булкин В.В., Федосеева Е.В., Ростокин И.Н. Радиометеорологические исследования в муромском институте: современное состояние и перспективы развития // Радиотехнические и телекоммуникационные системы. 2022. №4. С. 5–18.

9. Мезенин А., Мезенина М. Прогнозирование методом машинного обучения // Сборник научных трудов. Екатеринбург: Издательский дом «Ажур», 2023. 5 с. URL: <https://clar.urfu.ru/handle/10995/128538> (дата обращения 20.10.2025).

10. Hastie T., Tibshirani R., Friedman J. The Elements of Statistical Learning: Data Mining, Inference, and Prediction. New York: Springer, 2009. 533 p.

11. Егоров Д.П., Верина Я.В., Кравченко О.В. Разработка нейросетевого метода восстановления влажностного профиля атмосферы по данным наземного микроволнового радиометра-спектрометра // Современные проблемы дистанционного зондирования Земли из космоса: материалы XXI Международной конференции (Москва, 13–17 ноября 2023 г.). М.: ИКИ РАН, 2023. С. 1–27.

Поступила 20 октября 2025 г.

English

INVESTIGATION OF THE INFLUENCE OF THE FORECASTING HORIZON ON THE ACCURACY OF PREDICTING ATMOSPHERIC METEOROLOGICAL PARAMETERS FOR VARIOUS MACHINE LEARNING MODELS

Maksim Andreevich Matyukov — Postgraduate Student, “Vladimir State University¹ named after Alexander and Nikolay Stoletovs”.

Elena Valeryevna Fedoseeva — Grand Dr. in Engineering, Professor, Radioengineering Department, Murom Institute² (branch) of the “Vladimir State University named after Alexander and Nikolay Stoletovs”.

Ilya Nikolaevich Rostokin — Grand Dr. in Engineering, Professor, Department of Monitoring and Control in Engineering Systems, Murom Institute² (branch) of the “Vladimir State University named after Alexander and Nikolay Stoletovs”.

Georgy Georgyievich Shchukin — Grand Dr. in Engineering, Professor, the Head of the Laboratory, State Research Navigation and Hydrographic Institute (GNINGI)³.

¹Address: 600000, Russian Federation, Vladimir, Gorky st., 87.

²Address: 602264, Russian Federation, Vladimir region, Murom, Orlovskaya st., 23.

³Address: 199106, Russian Federation, Saint Petersburg, Kozhevennaya Line, 41.

E-mail: elenafedoseeva@yandex.ru

Abstract: The study is devoted to a quantitative assessment of the influence of the forecasting horizon on the accuracy of predicting near-surface atmospheric meteorological parameters using various machine learning models and multichannel microwave radiometry data. The relevance of the work is due to the need to improve the efficiency of operational atmospheric monitoring and the timely detection of hazardous meteorological phenomena. The research is based on measurement data from a microwave radiometer operating in

the city of Murom (August 2023 – December 2024) and synchronous meteorological observations. An approach to forming training samples is proposed, taking into account the temporal structure of data for forecasting horizons of 5, 30, and 120 minutes. Comparative testing of algorithms of varying complexity was performed: linear and polynomial regression, Random Forest, gradient boosting, and ensemble methods in the KNIME and Orange Data Mining software environments. It was established that with an increase in the forecasting horizon from 5 minutes to 2 hours, the accuracy of all models regularly decreases; however, the degree of degradation significantly depends on the type of algorithm. Ensemble methods (Tree Ensemble and Random Forest in KNIME) demonstrated the best stability: for a 5-minute temperature forecast, the correlation coefficient reached 87.8%, and for 2 hours it remained at the level of 66.4%. Linear methods showed insufficient efficiency for all horizons, especially for humidity. A fundamental difference in the predictability of parameters was revealed: temperature is predicted significantly more accurately than humidity, the forecast of which at a 2-hour horizon is practically unsuitable for applications ($R < 42\%$, $RMSE > 15\%$). At long horizons, most models exhibit a systematic shift in forecasts (Mean Model Error up to -7.36°C). Practical recommendations for model selection are formulated: for very short-term forecasting (5–30 minutes), Tree Ensemble and Random Forest (KNIME) are optimal; the 2-hour horizon is the limit for the used approach without taking into account temporal dynamics. To improve accuracy over long intervals, the use of recurrent neural networks is necessary. The results create a basis for building adaptive monitoring systems with flexible algorithm selection depending on the required lead time.

Keywords: machine learning, forecasting of meteorological parameters, forecasting horizon, microwave radiometry, neural networks, comparative analysis.

References

1. *Matyukov M.A., Fedoseeva E.V., Rostokin I.N.* et al. Analysis of neural network forecasting accuracy of meteorological parameters based on multi-frequency microwave radiometric measurements of the atmosphere. All-Russian Open Armand Readings: Modern Problems of Remote Sensing, Radar, Wave Propagation and Diffraction. 2024. No. 1. Pp. 506–511.
2. *Kalchbrenner N., Sønderby C.* A Neural Weather Model for Eight-Hour Precipitation Forecasting [Electronic source]. Google AI Blog. 2020. March 25. URL: <https://ai.googleblog.com/2020/03/a-neural-weather-model-for-eight-hour.html> (Access date 20.10.2025).
3. *Fedoseeva E.V., Rostokin I.N., Shchukin G.G.* et al. Neural network for short-term forecasting based on microwave radiometric sounding of the atmosphere. Radioengineering and Telecommunication Systems. 2023. No. 3. Pp. 20–28.
4. *Stepanenko V.D., Shchukin G.G., Bobylev L.P., Matrosov S.Yu.* Radiothermal Location in Meteorology. Leningrad: Gidrometeoizdat, 1987. 283 p.
5. *Kutuza B.G., Yakovlev O.I., Danilichev M.V.* Satellite Monitoring of the Earth: Microwave Radiometry of the Atmosphere and Surface. Monograph. Moscow: Lenand, 2016. 336 p.
6. *Kadygrov E.N.* Microwave Radiometry of Thermal Stratification of the Atmosphere. Moscow, 2020.
7. *Ware R.A.* A multichannel radiometric profiler of temperature, humidity, and cloud liquid. Radio Science. 2003. Vol. 38, Iss. 4. P. 8079. DOI: 10.1029/2002RS002856.
8. *Shchukin G.G., Bulkin V.V., Fedoseeva E.V., Rostokin I.N.* Radiometeorological research at Murom Institute: current state and development prospects. Radioengineering and Telecommunication Systems. 2022. No. 4. Pp. 5–18.
9. *Mezenin A., Mezenina M.* Forecasting using machine learning method. Collection of Scientific Papers. Yekaterinburg: Publishing House "Azhar", 2023. 5 p. URL: <https://elar.urfu.ru/handle/10995/128538> (Access date 20.10.2025).
10. *Hastie T., Tibshirani R., Friedman J.* The Elements of Statistical Learning: Data Mining, Inference, and Prediction. New York: Springer, 2009. 533 p.
11. *Egorov D.P., Verina Ya.V., Kravchenko O.V.* Development of a neural network method for retrieving atmospheric humidity profiles from ground-based microwave radiometer-spectrometer data. Modern Problems of Remote Sensing of the Earth from Space: Proceedings of the XXI International Conference (Moscow, November 13–17, 2023). Moscow: IKI RAS, 2023. Pp. 1–27.