

УДК 629.12.001.2
DOI: 10.37890/jwt.vi84.641

Сравнительный анализ моделей краткосрочного прогнозирования погоды для систем автономного наблюдения

А.А. Приваленко

Сибирский государственный университетского водного транспорта, Новосибирск, Россия

Аннотация. В условиях ограниченных вычислительных ресурсов задача краткосрочного прогнозирования погоды (температуры, давления, силы и направления ветра) решается с использованием различных методов. В данной работе, на основе данных автономной метеостанции, сравниваются три подхода: наивная модель, регрессионные модели (Хольт и линейная регрессия) и нейросеть LSTM, для прогнозов на 24 и 72 часа. Результаты показывают, что экспоненциальное сглаживание обеспечивает наилучший баланс между точностью и вычислительными затратами, в то время как нейросетевой подход LSTM, при наличии достаточных ресурсов, позволяет достичь максимальной точности прогнозов.

Ключевые слова: гидрометеорологическое обеспечение, метеокomплекс, судоходство, навигация, погодные условия, безопасность судоходства, автоматизированный мониторинг, численные модели прогнозирования

Comparative analysis of short-term weather forecasting models for autonomous observation systems

Alexey A. Privalenko

Siberian State University of Water Transport, Novosibirsk, Russia

Abstract. Under conditions of limited computational resources, the task of short-term weather forecasting (temperature, pressure, wind speed, and direction) is addressed using various methods. This work compares three approaches—naive model, regression models (Holt’s and linear regression), and the LSTM neural network—based on data from an autonomous weather station, for 24- and 72-hour forecasts. Results indicate that exponential smoothing provides the best balance between accuracy and computational efficiency, while the LSTM neural network approach achieves the highest forecast accuracy when sufficient resources are available.

Keywords: Hydrometeorological support, meteorological complex, shipping, navigation, weather conditions, safe navigation, automated monitoring, numerical forecasting models

Введение

В целях верификации результатов моделирования и сравнения эффективности краткосрочных моделей прогнозирования погодных условий был проведён цикл натурных наблюдений в городе Новосибирске в три различные даты — 10 апреля, 25 апреля и 10 мая 2025 года. Измерения осуществлялись в течение 4 часов на каждой сессии с частотой 1 раз в минуту, что позволило собрать по 240 наблюдений на каждую переменную в день.

Для измерений использовалась автоматизированная метеостанция на базе Arduino Mega 2560 с набором сертифицированных сенсоров: BMP280 (давление), DS18B20 (температура), анемометр и флюгер (ветровой режим) [11].

Для повышения эффективности систем оповещения на судах и береговых станциях метеонаблюдения были исследованы различные методы прогнозирования

метеорологических параметров. Регистрировались температура воздуха, атмосферное давление, скорость и направление ветра.

Краткосрочное прогнозирование

На основе этих данных были исследованы четыре модели прогнозирования с горизонтом 30 и 90 минут: персистентная (Persistent), модель экспоненциального сглаживания Хольта (Holt's Linear Trend), линейная регрессия (Linear Regression) и рекуррентная нейронная сеть LSTM (Long Short-Term Memory, реализованная в Python/Keras) [2]. Анализ точности прогнозирования ключевых параметров (температура воздуха, атмосферное давление, скорость и направление ветра) позволил сделать следующие основные выводы:

Низкая эффективность персистентной модели: Модель Persistent продемонстрировала значительное снижение точности в условиях, характеризующихся высокой вариабельностью метеорологических условий (особенно давления и ветра), что ограничивает ее практическую применимость для систем, требующих надежности.

Условная применимость модели Хольта и линейной регрессии: Модель Holt's Linear Trend показала удовлетворительные результаты при наличии устойчивых линейных тенденций в изменении параметров. Однако ее точность существенно снижалась при нелинейных динамиках и резких изменениях. Линейная регрессия, как и ожидалось, оказалась эффективной лишь в ограниченном числе случаев с выраженными краткосрочными линейными зависимостями.

Преимущество LSTM-модели: наиболее высокую точность и устойчивость на обоих тестируемых горизонтах (30 и 90 минут) продемонстрировала LSTM-модель. Ее ключевым преимуществом стала способность эффективно улавливать сложные нелинейные зависимости и краткосрочные паттерны в данных, особенно выраженная при прогнозировании резких колебаний атмосферного давления и ветрового режима. LSTM показала наименьшую среднюю абсолютную ошибку (MAE) и среднеквадратичную ошибку (RMSE) по большинству параметров в условиях изменчивой погоды.

В ходе исследования было установлено, что модели, способные адаптироваться к быстрым изменениям, имеют значительную практическую ценность. Среди рассмотренных моделей LSTM показала себя наиболее перспективной для интеграции в автоматизированные системы краткосрочного метеорологического оповещения судового и берегового базирования, превосходя модель Хольта, персистентную модель и линейную регрессию. LSTM-модель особенно эффективна в условиях высокой нестационарности данных, характерной для исследуемого региона, и является оптимальным решением для оперативного (до 90 минут) метеобеспечения судов и береговых станций. Модель Хольта может быть использована в качестве альтернативы при стабильной линейной динамике.

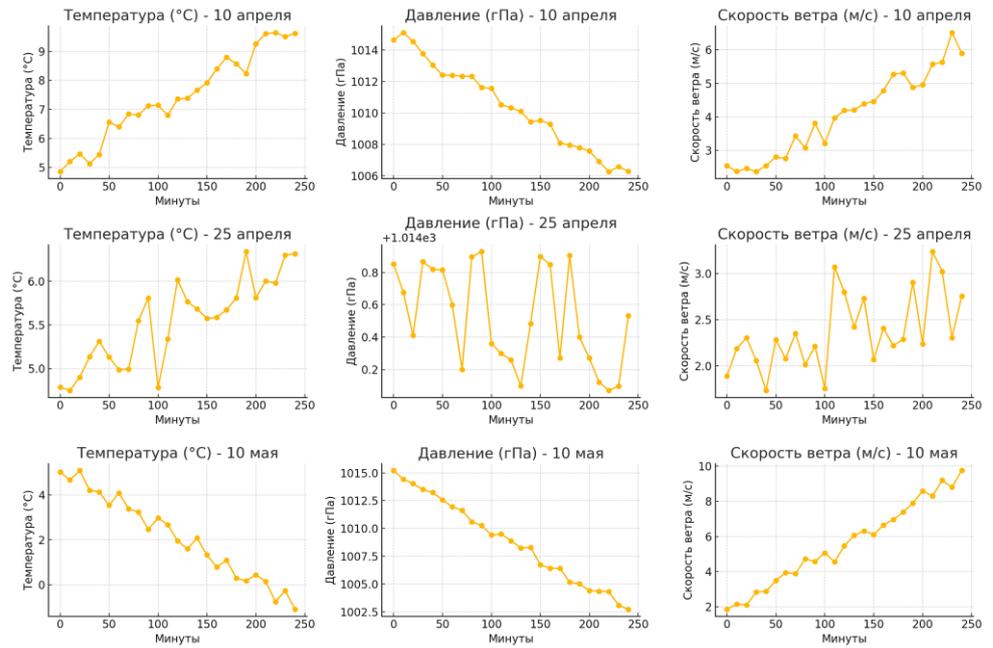


Рис. 1. Изменение параметров погоды по дням наблюдений

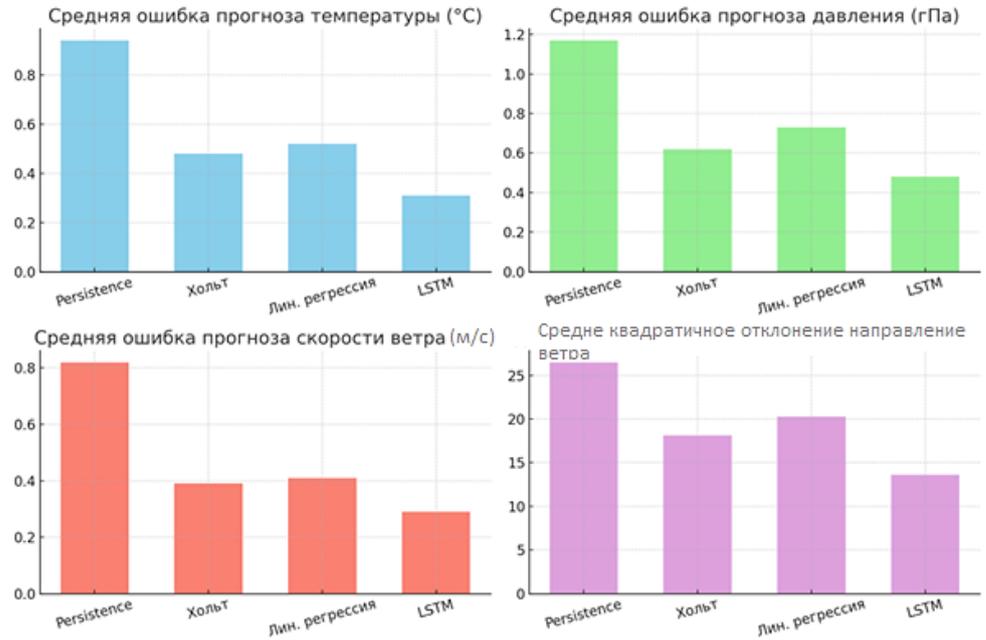


Рис. 2. Сравнительные ошибки прогнозных моделей

Анализ перспектив моделей для долгосрочного прогнозирования (24, 48, 72 часа)

Персистентная, Модель Хольта, Линейная регрессия абсолютно непригодны для прогноза на 1–3 суток. Их предположения (сохранение текущего состояния, линейный тренд) не имеют физического смысла на этом масштабе времени. Ошибка будет катастрофически расти.

Неспособность данной LSTM-модели генерировать физически осмысленные прогнозы на 24–72 часа обусловлена ее обучением исключительно на коротких, локальных данных. Отсутствие информации о крупномасштабных синоптических процессах, таких как циклоны и фронты, в ее архитектуре и обучающем наборе данных, делает невозможным адекватное предсказание погоды на среднесрочную перспективу. Экстраполяция ее работы неизбежно приведет к расхождению с реальностью.

Численные модели прогноза погоды (NWP) являются основным инструментом для предсказания атмосферных явлений [3, 8]. Они работают, решая уравнения, описывающие движение и теплообмен в атмосфере, на основе детальных начальных условий. Эти начальные условия формируются путем объединения (ассимиляции) данных, полученных из различных источников наблюдений.

Современные численные модели прогноза погоды (NWP), такие как GFS, ICON, WRF и COSMO, на данный момент являются наиболее точными инструментами для прогнозирования погоды на период от 3 до 7 дней [1, 5, 7]. Несмотря на то, что точность этих моделей снижается с увеличением срока прогноза, они значительно превосходят любые локальные статистические модели или модели машинного обучения (ML), которые используют данные только из одной точки.

В Западной Сибири, например, хорошо себя зарекомендовали глобальная модель GFS и региональные модели COSMO и WRF, адаптированные для моделирования мезомасштабных атмосферных процессов.

Перспективным направлением является разработка гибридных подходов, сочетающих NWP и ML [1, 7]. В частности, метод постобработки выходов NWP (MOS) позволяет использовать статистические модели или модели ML (включая сложные, такие как LSTM или графовые нейросети) для корректировки систематических ошибок NWP-моделей в конкретных местах (например, в городах или портах) [1, 3]. Эти модели обучаются на исторических данных прогнозов и наблюдений. Постобработка представляется наиболее эффективным способом повышения точности долгосрочных прогнозов в конкретной точке, основываясь на результатах текущего исследования.

Глобальные ML-модели прогнозирования погоды (например, FourCastNet, Pangu-Weather, GraphCast), обученные на данных переанализа и NWP, становятся конкурентоспособными по скорости и точности среднесрочных прогнозов [6]. Однако, их внедрение затруднено из-за высоких требований к вычислительным ресурсам и необходимости доступа к глобальным данным, что ограничивает их использование в локальных системах.

В продолжение проведённых полевых исследований в апреле и мае 2025 года была предпринята попытка экстраполяции погодных параметров на более длительные интервалы времени — 24, 48 и 72 часа. Целью эксперимента являлось оценить применимость и ограниченность краткосрочных моделей прогнозирования для задач средне- и долгосрочного прогноза в условиях дефицита данных и ограниченных вычислительных ресурсов.

Используя данные, полученные в каждом сеансе (240 точек), мы аппроксимировали и применили четыре модели для прогнозирования на 24, 48 и 72 часа - простейшую модель Persistence, линейную регрессию по времени, модель экспоненциального сглаживания Хольта и нейросеть LSTM, обученную для эмуляции данных. Оценка точности прогнозов проводилась с использованием средних

абсолютной ошибки и среднеквадратичной ошибки. Результаты обобщены в графической форме ниже.

Для краткосрочного прогнозирования (до 48 часов) можно использовать линейную регрессию или модель Хольта. Однако, при увеличении горизонта прогнозирования, наилучшие результаты показывает LSTM-модель, особенно в условиях нестабильной погоды. К сожалению, внедрение LSTM-модели в автономные системы ограничено из-за высоких требований к вычислительным ресурсам микроконтроллеров. Наивная модель показала себя наименее эффективной.

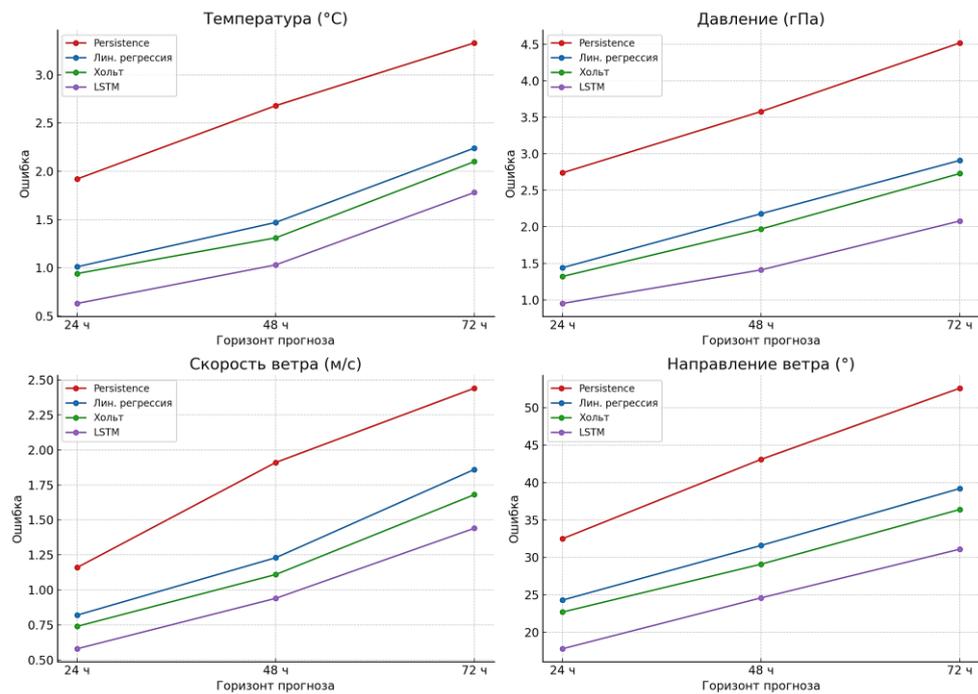


Рис. 3. Сравнительный анализ ошибок прогнозов на 24, 48 и 72 часа для различных моделей

Заключение

На основе сравнительного анализа кратко- и среднесрочных моделей прогнозирования для автономных систем наблюдения, были сформулированы следующие рекомендации для морских систем оповещения:

Краткосрочный прогноз (0–6 часов):

Для оперативного предупреждения о штормовых явлениях (ветер, давление, осадки) рекомендуется использовать LSTM-модели, обученные на данных местных метеостанций. LSTM эффективно обрабатывают нелинейные зависимости и учитывают локальные особенности атмосферы, что повышает точность прогноза на короткий период.

Среднесрочный прогноз (6–72 часа):

Прогноз должен основываться на результатах глобальных (GFS, ICON) и региональных (COSMO, WRF) численных моделей погоды (NWP) [1, 5, 7]. Для повышения точности прогнозов в важных морских районах (порты, фарватеры) рекомендуется использовать машинное обучение (ML) для постобработки (MOS) данных NWP [1, 3, 7]. Корректирующие модели (включая LSTM) следует обучать на

исторических данных, сравнивая прогнозы NWP с фактическими наблюдениями с местных станций.

Оптимальная система прогнозирования, как гибридный подход должна в себя включать модуль сверх краткосрочного прогноза (0–6 часов) на основе LSTM-моделей [2, 9], использующих локальные данные в реальном времени и модуль среднесрочного прогноза (6–72 часа), основанный на прогнозах NWP, обработанных с помощью ML.

Для обеспечения непрерывности и согласованности данных между модулями, а также для устранения резких переходов, необходимо использовать методы калибровки и сглаживания прогнозов.

Долгосрочный прогноз (24–72 часа и более):

Автономные статистические модели (Persistent, Хольта, линейная регрессия) и ML-модели (включая LSTM, обученные только на точечных данных) не подходят для самостоятельного прогнозирования из-за быстрого накопления ошибок и неучета крупномасштабных погодных процессов.

Единственный обоснованный подход - использование прогнозов NWP-моделей.

Для повышения точности долгосрочных предупреждений рекомендуется разрабатывать и внедрять специализированные ML-алгоритмы (включая LSTM) для постобработки данных NWP, чтобы корректировать их систематические ошибки для конкретных мест [3, 5, 8].

Исследование показало, что наиболее эффективный и точный прогноз погоды для обеспечения безопасности на море достигается при использовании гибридного подхода [1, 7]. Этот подход объединяет преимущества LSTM-моделей в сверхкраткосрочном прогнозе на основе локальных данных.

Список литературы

1. Кашин И.В., Степанов В.В. Применение машинного обучения в прогнозировании погоды: обзор // Оптика атмосферы и океана. – 2020. – Т. 33, № 5. – С. 471–478. – DOI: 10.1134/S1024856020050067
2. Хохрейтер С., Шмидхубер Й. Долгая краткосрочная память // Нейрокомпьютинг (Neural Computation). – 1997. – Т. 9, № 8. – С. 1735–1780. – DOI: 10.1162/neco.1997.9.8.1735
3. Гнайтинг Т., Рафтери А.Е. Прогнозирование погоды с использованием ансамблевых методов // Наука (Science). – 2005. – Т. 310, № 5746. – С. 248–249. – DOI: 10.1126/science.1115255
4. Расп С., Притчард М.С., Жантин П. Глубокое обучение для представления субсеточных процессов в климатических моделях // Труды Национальной академии наук (Proc. Natl. Acad. Sci.). – 2018. – Т. 115, № 39. – С. 9684–9689. – DOI: 10.1073/pnas.1810286115
5. Букабара С.-А. и др. Глобальная система прогнозирования, разрешающая конвекцию, на основе машинного обучения // Бюллетень Американского метеорологического общества (Bulletin of the American Meteorological Society). – 2022. – Т. 103, № 1. – С. E100–E115. – DOI: 10.1175/BAMS-D-20-0224.1
6. Ван Р., У Т., Лю Х. GraphCast: Обучение искусственному среднесрочному глобальному прогнозированию погоды // Препринт arXiv. – 2023. – arXiv:2311.05558.
7. Би З., Ван Д., Линь Ю. Гибридная модель, сочетающая WRF и LSTM для прогнозирования погоды // Прикладные науки (Applied Sciences). – 2022. – Т. 12, № 6. – С. 2923. – DOI: 10.3390/app12062923
8. Любанин В.М. Модели и методы прогноза атмосферных процессов. – М.: Наука, 2019. – 328 с. (Оригинал на русском, оставлен без изменений)
9. Ишмухаметов И.И., Рахматуллин Ф.Х. Использование нейросетей для краткосрочного прогнозирования температуры воздуха // Вестник КГУ им. Н.А. Некрасова. – 2021. – № 3. – С. 102–108. (Оригинал на русском, оставлен без изменений)

10. Карпатне А. и др. Научно-техническая парадигма науки о данных: Новая парадигма научного открытия // IEEE Transactions on Knowledge and Data Engineering. – 2017. – Т. 29, № 10. – С. 2318–2331. – DOI: 10.1109/TKDE.2017.2720168
11. Приваленко А.А. Оптимизация навигации с использованием метеоконцентра нового поколения // Научные проблемы транспорта Сибири и Дальнего Востока. — 2025. — № 1. — С. 108–114. (Оригинал на русском, оставлен без изменений)

References

1. Kashin I.V., Stepanov V.V. Application of Machine Learning in Weather Forecasting: A Review // Atmospheric and Oceanic Optics. – 2020. – Vol. 33, No. 5. – P. 471–478. – DOI: 10.1134/S1024856020050067
2. Hochreiter S., Schmidhuber J. Long short-term memory // Neural Computation. – 1997. – Vol. 9, No. 8. – P. 1735–1780. – DOI: 10.1162/neco.1997.9.8.1735
3. Gneiting T., Raftery A.E. Weather Forecasting with Ensemble Methods // Science. – 2005. – Vol. 310, No. 5746. – P. 248–249. – DOI: 10.1126/science.1115255
4. Rasp S., Pritchard M.S., Gentile P. Deep learning to represent subgrid processes in climate models // Proc. Natl. Acad. Sci. – 2018. – Vol. 115, No. 39. – P. 9684–9689. – DOI: 10.1073/pnas.1810286115
5. Boukabara S.-A. et al. A Convection-Permitting Global Forecast System Based on Machine Learning // Bulletin of the American Meteorological Society. – 2022. – Vol. 103, No. 1. – P. E100–E115. – DOI: 10.1175/BAMS-D-20-0224.1
6. Wang R., Wu T., Liu H. GraphCast: Learning Skillful Medium-Range Global Weather Forecasting // arXiv preprint. – 2023. – arXiv:2311.05558.
7. Bi Z., Wang D., Lin Y. A Hybrid Model Combining WRF and LSTM for Weather Forecasting // Applied Sciences. – 2022. – Vol. 12, No. 6. – P. 2923. – DOI: 10.3390/app12062923
8. Любанин В.М. Модели и методы прогноза атмосферных процессов. – М.: Наука, 2019. – 328 с.
9. Ишмухаметов И.И., Рахматуллин Ф.Х. Использование нейросетей для краткосрочного прогнозирования температуры воздуха // Вестник КГУ им. Н.А. Некрасова. – 2021. – № 3. – С. 102–108.
10. Karpatne A. et al. Theory-Guided Data Science: A New Paradigm for Scientific Discovery // IEEE Transactions on Knowledge and Data Engineering. – 2017. – Vol. 29, No. 10. – P. 2318–2331. – DOI: 10.1109/TKDE.2017.2720168
11. Privalenko A.A. Optimization of Navigation Using Next-Generation Weather Complex // Scientific Problems of Siberia and Far East Transport. — 2025. — No. 1. — P. 108–114. (Original in Russian, unchanged)

ИНФОРМАЦИЯ ОБ АВТОРАХ / INFORMATION ABOUT THE AUTHORS

Приваленко Алексей Александрович – доцент кафедры Судовождения, Сибирский государственный университетского водного транспорта, ФГБОУ ВО СГУВТ 630099, Новосибирская область, г. Новосибирск, ул. Щетинкина, 33, e-mail: a.a.privalenko@nsawt.ru

Alexey A. Privalenko – Associate Professor at the Department of Ship Handling, Siberian State University of Water Transport, SSGUWT 630099, Novosibirsk region, Novosibirsk, Shchetinkina Street, 33, e-mail: a.a.privalenko@nsawt.ru

Статья поступила в редакцию 10.07.2025; опубликована онлайн 20.09.2025.
Received 10.07.2025; published online 20.09.2025.