

УДК 004.657

1.2.2. Математическое моделирование, численные методы и комплексы программ

ДОЛГОСРОЧНОЕ ПРОГНОЗИРОВАНИЕ СРЕДНЕМЕСЯЧНОЙ ТЕМПЕРАТУРЫ НА ОСНОВЕ ИЕРАРХИЧЕСКОГО ЧЕТЫРЁХ-УРОВНЕВОГО АНСАМБЛЯ С ДИНАМИЧЕСКОЙ КЛИМАТИЧЕСКОЙ НОРМОЙ И СТАТИСТИЧЕСКИ ОБОСНОВАННОЙ ВЕРИФИКАЦИЕЙ

Богус Азамат Эдуардович
доцент кафедры «Процессы и машины в агробизнесе»
SPIN-код: 9567-1848
email: azamat089@gmail.com
ФГБОУ ВО «Кубанский ГАУ», Краснодар, Россия

Шершнёв Игорь Андреевич
студент факультета механизации
email: igor.sh06@mail.ru
ФГБОУ ВО «Кубанский ГАУ», Краснодар, Россия

Разработана и статистически обоснована система долгосрочного прогнозирования среднемесячной температуры приземного воздуха с горизонтом до 12 месяцев на основе иерархического четырёх-уровневого ансамбля. Верификация проведена методом walk forward для метеостанции Краснодар на шести независимых тестовых годах (2007, 2011, 2020–2023), охватывающих 72 месяца. Средняя абсолютная ошибка (MAE) предложенной системы составила 1,88 °C, тогда как для климатологии – 3,24 °C, для персистентности – 3,95 °C, для линейной регрессии – 3,36 °C. Относительное преимущество над климатологией (skill score) достигает 0,42. Бутстреп-анализ (10 000 повторений) дал 95 % доверительный интервал MAE [1,59; 2,17] °C. Парные статистические тесты подтверждают значимость различий ($p < 0,001$). Тест Льюнга–Бокса не выявил автокорреляции остатков ($p > 0,5$ для лагов 1–12). Иерархическая архитектура превосходит единичную крупную модель градиентного бустинга примерно на 20 % по MAE. Результаты демонстрируют устойчивое и статистически значимое преимущество предложенного подхода, что открывает перспективы для сельского хозяйства, энергетики и климатического обслуживания

Ключевые слова: ДОЛГОСРОЧНЫЙ ПРОГНОЗ ТЕМПЕРАТУРЫ, АНСАМБЛЬ МОДЕЛЕЙ, ГРАДИЕНТНЫЙ БУСТИНГ, НЕЙРОННЫЕ СЕТИ, ДИНАМИЧЕСКАЯ КЛИМАТИЧЕСКАЯ НОРМА, WALK-FORWARD ВЕРИФИКАЦИЯ, СТАТИСТИЧЕСКАЯ ОЦЕНКА

<http://dx.doi.org/10.21515/1990-4665-220-003>

UDC 004.657

1.2.2. Mathematical modeling, numerical methods and software packages

LONG-TERM FORECASTING OF MONTHLY MEAN TEMPERATURE BASED ON A HIERARCHICAL FOUR-LEVEL ENSEMBLE WITH DYNAMIC CLIMATE NORM AND STATISTICALLY RIGOROUS VERIFICATION

Bogus Azamat Eduardovich
Associate Professor, Department of Processes and Machines in Agribusiness
SPIN-code: 9567-1848
email: azamat089@gmail.com
FSBEI HE Kuban SAU, Krasnodar, Russia

Shershnev Igor Andreevich
student of the Faculty of Mechanization
email: igor.sh06@mail.ru
FSBEI HE Kuban SAU, Krasnodar, Russia

A long-term forecasting system for average monthly surface air temperature with a horizon of up to 12 months has been developed and statistically validated based on a hierarchical four-level ensemble. Verification was carried out using the walk forward method for the Krasnodar weather station over six independent test years (2007, 2011, 2020–2023), covering 72 months. The mean absolute error (MAE) of the proposed system was 1.88 °C, while for climatology it was 3.24 °C, for persistence it was 3.95 °C, and for linear regression it was 3.36 °C. The relative advantage over climatology (skill score) reaches 0.42. Bootstrap analysis (10,000 repetitions) yielded a 95% confidence interval of MAE [1.59; 2.17] °C. Paired statistical tests confirm the significance of the differences ($p < 0.001$). The Ljung–Box test revealed no autocorrelation of the residuals ($p > 0.5$ for lags 1–12). The hierarchical architecture outperforms a single large gradient boosting model by approximately 20% in MAE. The results demonstrate a robust and statistically significant advantage of the proposed approach, which offers potential for agriculture, energy, and climate services

Keywords: LONG-RANGE TEMPERATURE FORECAST, MODEL ENSEMBLE, GRADIENT BOOSTING, NEURAL NETWORKS, DYNAMIC CLIMATE NORM, WALK-FORWARD VERIFICATION, STATISTICAL EVALUATION

<http://ej.kubagro.ru/2026/06/pdf/03.pdf>

Введение

Долгосрочное прогнозирование температуры воздуха на горизонтах от одного месяца до года имеет высокую практическую ценность для планирования в сельском хозяйстве (сроки сева, уборки, расход удобрений), энергетике (прогноз нагрузки), водном хозяйстве и адаптации к изменениям климата. Несмотря на стремительное развитие динамических моделей общей циркуляции атмосферы и океана, их прямое использование для локальных месячных прогнозов сталкивается с принципиальными ограничениями: низкое пространственное разрешение, систематические ошибки воспроизведения региональных процессов, высокая внутренняя изменчивость атмосферы на синоптических масштабах и недостаточная предсказуемость на сезонных промежутках времени [1–3]. В этих условиях статистические и гибридные (физико-статистические) подходы, опирающиеся на исторические ряды наблюдений, крупномасштабные климатические индексы и поля геопотенциала, способны значительно повысить качество локальных прогнозов.

Современные исследования показывают, что ансамбли из нескольких разнородных моделей, как правило, превосходят отдельные модели за счёт усреднения некоррелированных ошибок и подавления переобучения [4]. Однако для задач долгосрочного прогнозирования температуры ключевыми проблемами остаются корректный учёт долгопериодного климатического тренда, обработка нестационарности временных рядов и строгая процедура верификации, исключая утечку информации из будущего в обучение.

Наблюдаемое изменение климата выражается в устойчивом росте температуры. Например, для Краснодара линейный тренд среднемесячной температуры за 1980–2023 гг. составляет около $+0,52\text{ }^{\circ}\text{C}$ за десятилетие ($R^2 = 0,18$). Использование фиксированной климатической нормы (например,

за 1961–1990 гг.) в такой ситуации приводит к систематическому занижению прогнозов и росту ошибок. Поэтому необходим механизм динамической нормы, ежегодно обновляемой по доступной истории.

Цель настоящей работы – разработка и строгая статистическая оценка ансамблевой системы долгосрочного прогнозирования среднемесячной температуры на основе четырёхуровневой иерархической архитектуры с динамической нормой, трендовой адаптацией и нейросетевым постпроцессингом. Работа также демонстрирует полный цикл walk-forward верификации и развёрнутое статистическое обоснование полученных результатов.

Исходные данные и предварительная обработка

Источники данных. В работе использованы следующие массивы метеорологической и климатической информации:

- ERA5 – ежечасные поля реанализа Европейского центра среднесрочных прогнозов погоды (ECMWF) за период 1979–2023 гг. с пространственным разрешением $0,25^\circ \times 0,25^\circ$. Для точки, соответствующей метеостанции Краснодар, извлечены температура на высоте 2 м, давление на уровне моря, удельная влажность, количество осадков и скорость ветра.

- Архив наблюдений метеостанции Краснодар (WMO ID 34927) – ежечасные данные за 1979–2023 гг., включая температуру, влажность, давление, осадки, скорость и направление ветра, облачность и точку росы. Данные наземной станции использовались в качестве целевой переменной для верификации, а также для дополнения пропусков в ERA5.

- Глобальные климатические индексы (NOAA, CPC, ECMWF): Southern Oscillation Index (SOI), Niño 3.4, NAO (Азорский и Исландский), Arctic Oscillation (AO), Pacific Decadal Oscillation (PDO), Atlantic Multidecadal Oscillation (AMO), Quasi-Biennial Oscillation (QBO), SCAND,

East Atlantic (EA), East Atlantic/Western Russia (EAWR) и др. Индексы представлены в виде месячных аномалий.

- Архивные прогнозы GFS (Global Forecast System) – оперативные данные с 2007 г., содержащие прогнозы температуры, давления и осадков с заблаговременностью до 384 часов. Используются в качестве источника краткосрочной информации для модели с MOS-коррекцией.

- Геопотенциал 500 гПа – ежечасные значения в узлах регулярной сетки для трёх зональных полос: 40° с.ш., 60° с.ш. и полярная область (60–90° с.ш.). Использованы для расчёта главных компонент (РСА) крупномасштабной циркуляции.

Доступность данных по годам неоднородна: наиболее полные ряды начинаются с 1979 г., архивы GFS – с 2007 г. Система автоматически определяет наличие информации и при отсутствии GFS заменяет его климатологией.

Агрегация по временным масштабам

Все исходные ежечасные данные агрегированы до трёх основных уровней:

1. Суточный – среднесуточная, минимальная, максимальная температура; амплитуда; суточные суммы осадков; среднее, минимальное и максимальное давление; скорость ветра; влажность; аномалии относительно нормы; число часов с отрицательной температурой, с температурой выше 30 °С; интенсивные осадки и т.д. Сутки считаются валидными при наличии не менее 6 часов наблюдений.

2. Декадный (декады месяца: 1–10, 11–20, 21–последнее число). Рассчитываются средние, минимальные и максимальные значения параметров по дням декады, дополнительно тренды температуры и давления внутри декады, доля дней с блокирующими антициклонами, число дней с

заморозками и осадками, надёжность декадного прогноза, характеристики влажности почвы и снежного покрова (из дополнительных архивов).

3. Месячный – взвешенные средние по декадам с весами, равными числу дней. Дополнительно вычисляются тренды температуры и давления от первой к третьей декаде, флаг наличия блокинга, аномалии, процентиля ENSO и NAO относительно исторического распределения, циклические признаки (сезон, цикл QBO, фазы AMO и ENSO).

Такая агрегация позволяет сформировать компактные, но информативные признаковые описания для трёх временных масштабов.

Динамическая климатическая норма и предотвращение утечки данных

Ключевым методическим требованием является полное исключение использования будущей информации при формировании любых статистических параметров. Для каждого прогнозируемого года Y климатическая норма (среднемесячная температура, давление, осадки, стандартное отклонение) рассчитывается строго по периоду 1979–($Y-1$) гг. Процесс повторяется для каждого тестового года, т.е. норма динамически «дрейфует» вслед за наблюдаемым климатом. При вычислении аномалий (температуры, давления и т.д.) используется та же скользящая норма, что гарантирует отсутствие заглядывания вперёд. Аналогичный подход применён при расчёте процентилей индексов ENSO и NAO: распределение строится только по годам, предшествующим целевому.

Анализ главных компонент геопотенциала

Для компактного описания крупномасштабной циркуляции использован метод главных компонент (PCA) [5]. По ежечасным данным геопотенциала H500 для трёх широтных зон (40N, 60N, polar) сначала выполнено осреднение до суточного, декадного и месячного разрешения. Для каж-

дого масштаба отдельно (дневной, декадный, месячный) построена РСА-модель по данным, ограниченным годами обучения ($Y < \text{целевого}$). Извлекались первые две главные компоненты, объясняющие в совокупности не менее 75 % дисперсии исходных полей. Проекции вычислялись для всех доступных дней/декад/месяцев. Этот подход идентичен глобальному РСА без региональной детализации.

Итоговый набор признаков

После всех этапов агрегации, расчёта норм и аномалий, добавления циклических тригонометрических признаков ($\sin/\cos$ месяца для учёта сезонности) и РСА-проекций формируется итоговое пространство признаков. Для месячного прогноза используется 34 признака, описывающих температуру, осадки, давление, ветер, влажность, климатические индексы, показатели блокинга, тренды, фазы телеконнекций и др. Аналогичные векторы (с поправкой на масштаб) строятся для дневного и декадного уровней (~28 и 21 признак соответственно).

Архитектура системы прогнозирования

Предлагаемая система является многоуровневым ансамблем, в котором каждый последующий уровень корректирует ошибки предыдущего, используя всё более широкий контекст. Схема включает четыре уровня (рисунок 1).




Рисунок 1 – Блок-схема иерархического ансамбля $L1 \rightarrow L2 \rightarrow L3 \rightarrow L4$

Уровень L1 – первичный ансамбль

На первом уровне три независимые модели дают прогноз среднемесячной (среднедекадной, среднесуточной) температуры:

1. Модель A (Gradient Boosting Machine, GBM). Стандартный градиентный бустинг над деревьями решений [6] с параметрами: 100 деревьев, максимальная глубина 4, learning rate 0.1, L2-регуляризация 1.0, доля подвыборки 0.8. Модель обучается в режиме walk-forward отдельно для каждого целевого года: используется вся доступная история до $(Y-1)$ года, но не менее 5 лет обучения. Признаки – предыдущий (или текущий) временной срез, не включающий целевую температуру этого же месяца, чтобы избежать утечки (например, для месячного прогноза используются признаки текущего месяца, а цель – температура следующего месяца). Этот принцип строго соблюдается на всех масштабах.

2. Модель B (динамическая климатология с MOS-коррекцией GFS). На месячном масштабе модель B представляет собой динамическую норму, скорректированную на текущие значения ENSO и NAO с эмпирическими коэффициентами. При наличии доступных прогнозов GFS (в основ-

ном для суточного и декадного разрешения) применяется Model Output Statistics (MOS) коррекция: систематическая ошибка GFS оценивается по историческим данным за аналогичный месяц и категорию «свежести» прогноза, после чего прогноз GFS смешивается с климатологией с весами, пропорциональными надёжности GFS. Такой подход позволяет извлечь полезную информацию из краткосрочного прогноза, не внося ложной точности на больших горизонтах.

3. Модель С (метод аналогов по PCA). Поиск аналогов осуществляется в пространстве первых двух глобальных главных компонент геопотенциала H500 с учётом календарного окна. Для каждого запроса выбираются K лучших аналогов (K=10) из прошлого, строго до даты запроса. Близость определяется взвешенным евклидовым расстоянием, а вес аналога экспоненциально убывает с разницей в индексах ENSO и NAO. Итоговый прогноз температуры и осадков вычисляется как взвешенное среднее по найденным аналогам.

Предсказания трёх моделей (А, В, С) объединяются в единый прогноз с помощью адаптивных весов. Веса определяются сглаженными (ЕМА) оценками точности моделей за предыдущие дни/декады/месяцы. Кроме того, учитывается согласованность ансамбля: если разброс моделей мал, вес ансамбля повышается, если велик – понижается. Итоговыми продуктами уровня L1 являются среднее ансамбля, его стандартное отклонение, минимальное и максимальное значения, разброс (spread), показатель согласованности (agree mode) и уверенность.

Уровень L2 – коррекция остаточной ошибки

На втором уровне три дополнительные GBM-модели (обозначаемые D, E, Zh) обучаются предсказывать остаточную ошибку ансамбля L1 относительно фактических значений. Все три модели оперируют признаками, которые не содержат целевой температуры в явном виде:

- Модель D предсказывает разность (факт – среднее L1), используя в качестве признаков характеристики ансамбля L1 (среднее, разброс, согласие, ЕМА-оценки) и предыдущее значение фактической температуры.

- Модель E предсказывает непосредственно фактическую температуру, опираясь на сезонные признаки (sin/cos месяца, номера декад, климатические индексы), но не на выход L1. Это позволяет выявить систематические сезонные ошибки, не связанные с ансамблем.

- Модель Zh обучается на подпространстве признаков модели E, полученном случайным отбором 75 % столбцов, с добавлением среднего L1. Такая «жадная» модель с повышенными требованиями к качеству (более жёсткий порог переобучения, штраф за высокую ошибку) предназначена для улавливания сложных нелинейностей.

Выходы моделей D, E, Zh объединяются через взвешенное голосование с учётом их исторических ошибок на отложенной выборке. Веса назначаются обратно пропорционально ошибке, а модели с экстремально высокими ошибками исключаются. Итоговый прогноз L2 получается как медиана или взвешенное среднее трёх скорректированных значений.

Уровень L3 – трендовая адаптация и физические ограничения

Практика показывает, что прогнозы L2 могут содержать медленно меняющееся систематическое смещение, особенно в условиях климатического тренда. Для его компенсации вводится адаптивный трендовый корректор:

- По последним N месяцам ($N = 10$) вычисляется скользящая медиана ошибок (факт – L2).

- Если медиана статистически надёжна (число известных фактов не менее 3), она умножается на весовой коэффициент, зависящий от индекса хаотичности Gating Network и разброса ансамбля L2. Коэффициент снижа-

ет влияние коррекции в хаотические периоды и периоды несогласия моделей.

- Корректирующая поправка ограничивается максимально допустимым значением (± 3 °C), после чего прибавляется к прогнозу L2.

Далее применяется «физический клиппинг» – ограничение прогноза температуры диапазоном, характерным для данного месяца в Краснодаре. Эти диапазоны основаны на абсолютных исторических минимумах и максимумах с небольшим запасом (например, для января от -25 до $+15$ °C). Такой приём предотвращает выдачу физически невозможных значений и повышает робастность.

Уровень L4 – нейросетевой постпроцессор

Заключительный уровень агрегирует всю цепочку коррекций и добавляет долгосрочный контекст через календарный год. Используется полносвязная нейронная сеть с двумя скрытыми слоями (64 и 32 нейрона, активация LeakyReLU), на вход которой подаются:

- Характеристики L1 (среднее, разброс, согласованность, веса моделей).
- Характеристики L2 (скорректированное значение, его разброс, показатели качества моделей D, E, Zh).
- Результат L3 (исходящее значение, трендовая поправка, внутренняя дельта).
- Индекс хаоса и режим (от Gating Network).
- Нормализованный год: $(year - 1980)/50$.

Сеть предсказывает одновременно корректирующую добавку (остаточную ошибку) и уверенность прогноза. Обучение выполняется методом Adam (learning rate 0.001, $\beta_1=0.9$, $\beta_2=0.999$, weight decay 0.01) с early stopping при отсутствии улучшений на валидационной выборке в течение 10 эпох. Для повышения обобщающей способности из обучающей выбор-

ки удаляются экстремальные выбросы, где абсолютная ошибка коррекции превышает утроенное стандартное отклонение остатков. Это гарантирует, что сеть не подстраивается под единичные аномалии.

После применения поправки L4 полученное значение проходит ещё один цикл физического клиппинга.

Оценка неопределённости

Для каждого прогноза рассчитывается 90 % доверительный интервал. Ширина интервала зависит от трёх факторов:

- базовой климатической сигмы месяца (σ_{base}) – исторической изменчивости температуры в данный месяц, оценённой по тренировочному периоду;

- коэффициента режима ($mode_coeff$): 1.0 для спокойного режима, 1.5 для переходного, 2.0 для хаотического;

- коэффициента горизонта ($horizon_coeff$), линейно интерполируемого между опорными точками: 1 месяц – 1.0, 3 мес. – 1.4, 6 мес. – 1.8, 12 мес. – 2.2.

Итоговая полуширина $CI90 = 1.645 \times \sigma_{base} \times mode_coeff \times horizon_coeff$.

Финальный прогноз

Итоговый прогноз на месячном горизонте формируется инференс-движком, который последовательно прогнозирует каждый следующий месяц, используя предыдущий прогноз в качестве входного факта для следующего шага (режим распространения). При этом внутренние состояния (уверенность, хаос-индекс, трендовые поправки) эволюционируют по своим законам. Прогнозы на дневных и декадных масштабах могут использоваться для построения внутримесячных распределений, но основным продуктом является месячное осреднение.

Дизайн эксперимента и верификация

Walk-forward процедура

Для получения несмещённых оценок точности применялась строгая walk-forward верификация [7]. Для каждого тестового года Y модель полностью переобучалась с использованием всех данных, доступных до Y . Процесс повторялся для каждого года из тестового набора, после чего все прогнозы объединялись и рассчитывались метрики. Это исключает любую утечку информации и соответствует реальной оперативной ситуации.

Тестовые годы: 2007, 2011, 2020, 2021, 2022, 2023 – всего 6 лет, 72 независимых месячных прогноза (для каждого года модель выдаёт 12 прогнозов вперёд, начиная с первого месяца после последнего наблюдаемого). Все прогнозы верифицированы по фактическим данным метеостанции Краснодар.

Базовые модели для сравнения

- Климатология – прогноз равен среднемноголетней температуре данного месяца за период 1979–($Y-1$) гг. (динамическая норма без поправок).
- Персистентность – прогноз равен температуре предыдущего месяца (наивный прогноз).
- Линейная регрессия – множественная линейная регрессия на тех же признаках, что и модель A уровня $L1$, обучаемая в walk-forward.
- Монолитный GBM – один мощный градиентный бустинг (500 деревьев, глубина 6) на всём наборе признаков.

Метрики и статистические тесты

Основная метрика – средняя абсолютная ошибка (MAE). Дополнительно вычислялись:

- смещение (bias),
- коэффициент детерминации R^2 ,
- skill score относительно климатологии: $SS = 1 - MAE_{model} / MAE_{clim}$.

Для оценки статистической значимости превосходства модели над каждой из базовых линий использовался бутстреп (10 000 повторений с возвратом) для построения 95 % доверительных интервалов разности MAE. Если интервал не включает ноль, различие значимо на уровне 0.05.

Наличие автокорреляции остатков проверялось критерием Льюнга–Бокса для лагов 1, 3, 6, 12.

Результаты

Основные показатели точности

Таблица 1 – Средняя абсолютная ошибка прогноза среднемесячной температуры, °C

Модель	MAE	Смещение
Предложенная система (L1+L2+L3+L4)	1.88	–0.12
Климатология	3.24	–0.05
Персистентность	3.95	–0.22
Линейная регрессия	3.36	0.31
Монолитный GBM	2.34	–0.18




Рисунок 2 – Диаграмма рассеяния прогнозируемой и фактической средне-
месячной температуры для 6 тестовых лет (2007, 2011, 2020–2023)

Описательная статистика ошибок

Таблица 2 – Характеристики распределения абсолютных ошибок, °C

Показатель	Система	Климатология
Среднее	1.88	3.24
Стандартное отклонение	1.12	1.64
Медиана	1.65	3.10
Межквартильный размах (IQR)	1.50	2.30
Минимум	0.08	0.15
Максимум	5.22	7.10




Рисунок 3 – Ящичковые диаграммы абсолютных ошибок для пяти сравниваемых моделей: Система (L1+L2+L3+L4), Климатология, Персистентность, Линейная регрессия и Монолитный GBM

Skill score

$SS = 1 - 1.88 / 3.24 = 0.42$ (улучшение на 42 %). Относительно монолитного GBM $SS = 0.20$.

Изменение ошибки с увеличением горизонта прогнозирования показано на рисунке 4.




Рисунок 4 – Средняя абсолютная ошибка прогноза средней месячной температуры в зависимости от горизонта (1–12 месяцев) для предложенной системы и климатологии

Бутстреп-оценки

Таблица 3 – Бутстреп (10 000 повторений) – 95 % ДИ для MAE

Модель	Нижняя граница	Верхняя граница
Система	1.59	2.17
Климатология	2.92	3.56

Разность MAE (климатология – система): 95 % ДИ [0.97; 1.83] ($p < 0.001$).




Рисунок 5 – Лесной график средних значений MAE и их 95 % доверительных интервалов, полученных бутстрепом (10 000 выборок) для пяти моделей

Автокорреляция остатков

Таблица 4 – Тест Льюнга–Бокса

Лаг	Q	p-value
1	0.41	0.52
3	1.87	0.60
6	3.14	0.79
12	5.32	0.94

Устойчивость по годам

Таблица 5 – MAE по тестовым годам, °C

Год	Система	Климатология
2007	3.21	3.40
2011	2.21	3.41
2020	1.41	3.52
2021	1.40	2.89
2022	1.39	3.12
2023	1.67	3.28

Вклад отдельных уровней

Анализ абляции: удаление L4 → MAE 2.05 °C; только L1+L2 → 2.34 °C; только модель A → 2.52 °C. Каждый уровень даёт положительный вклад.

Оценка неопределённости

В 87 % случаев фактическая температура попадала в 90 % доверительный интервал, что свидетельствует о хорошей калибровке.

Обсуждение

Результаты подтверждают эффективность иерархической архитектуры. Ключевые факторы:

- динамическая норма, отслеживающая тренд;
- объединение трёх разнородных источников информации;
- последовательная коррекция ошибок;
- строгая walk-forward процедура.

Динамическая норма особенно важна: для января 2023 г. статическая норма (1981–2010) ≈ -1.5 °C, динамическая ≈ -0.4 °C, что даёт разни-

цу в 1.1 °C. Метод аналогов позволяет улавливать редкие циркуляционные режимы. MOS-коррекция GFS даёт дополнительный выигрыш на коротких горизонтах (~0.3 °C). Иерархический ансамбль на 20 % превосходит монолитный GBM, что согласуется с теорией композиционного обучения.

Ограничения: валидация на одной станции; региональный РСА не активирован. Перспективы – мультистанционная верификация, прогноз осадков, вероятностные продукты.

Заключение

Разработана, программно реализована и верифицирована система долгосрочного прогноза среднемесячной температуры на основе четырёх-уровневого ансамбля с динамической нормой. На 72 независимых месяцах для Краснодара достигнута MAE 1.88 °C, что на 42 % ниже климатологии. Преимущество статистически значимо ($p < 0.001$), автокорреляция остатков отсутствует. Система готова к опытной эксплуатации в задачах агрометеорологического обслуживания.

Список литературы

1. Wilks D.S. Statistical Methods in the Atmospheric Sciences. 4th ed. Elsevier, 2019. 818 p.
2. Hersbach H., Bell B., Berrisford P. et al. The ERA5 global reanalysis // Quarterly Journal of the Royal Meteorological Society. 2020. Vol. 146, Iss. 730. P. 1999–2049.
3. Bauer P., Thorpe A., Brunet G. The quiet revolution of numerical weather prediction // Nature. 2015. Vol. 525. P. 47–55.
4. Hagedorn R., Doblas-Reyes F.J., Palmer T.N. The rationale behind the success of multi-model ensembles in seasonal forecasting – I. Basic concept // Tellus A. 2005. Vol. 57, Iss. 3. P. 219–233.
5. Hannachi A., Jolliffe I.T., Stephenson D.B. Empirical orthogonal functions and related techniques in atmospheric science: A review // International Journal of Climatology. 2007. Vol. 27. P. 1119–1152.
6. Friedman J.H. Greedy function approximation: A gradient boosting machine // The Annals of Statistics. 2001. Vol. 29, No. 5. P. 1189–1232.
7. Arlot S., Celisse A. A survey of cross-validation procedures for model selection // Statistics Surveys. 2010. Vol. 4. P. 40–79.

References

1. Wilks D.S. Statistical Methods in the Atmospheric Sciences. 4th ed. Elsevier, 2019. 818 p.
2. Hersbach H., Bell B., Berrisford P. et al. The ERA5 global reanalysis // Quarterly Journal of the Royal Meteorological Society. 2020. Vol. 146, Iss. 730. P. 1999–2049.
3. Bauer P., Thorpe A., Brunet G. The quiet revolution of numerical weather prediction // Nature. 2015. Vol. 525. P. 47–55.
4. Hagedorn R., Doblas-Reyes F.J., Palmer T.N. The rationale behind the success of multi-model ensembles in seasonal forecasting – I. Basic concept // Tellus A. 2005. Vol. 57, Iss. 3. P. 219–233.
5. Hannachi A., Jolliffe I.T., Stephenson D.B. Empirical orthogonal functions and related techniques in atmospheric science: A review // International Journal of Climatology. 2007. Vol. 27. P. 1119–1152.
6. Friedman J.H. Greedy function approximation: A gradient boosting machine // The Annals of Statistics. 2001. Vol. 29, No. 5. P. 1189–1232.
7. Arlot S., Celisse A. A survey of cross-validation procedures for model selection // Statistics Surveys. 2010. Vol. 4. P. 40–79.