

**ГЕОГРАФИЯ. ГЕОЭКОЛОГИЯ**  
**GEOGRAPHY. GEOECOLOGY**

УДК 551.509.313:004.032.26

Поступила в редакцию 23.10.2025

Received 13.10.2025

**КОРРЕКЦИЯ ОШИБОК МЕЗОМАСШТАБНОГО ЧИСЛЕННОГО  
ПРОГНОЗА ПОГОДЫ МЕТОДАМИ МАШИННОГО ОБУЧЕНИЯ****С. А. Лысенко, К. С. Юдыцкая***Институт природопользования НАН Беларуси, Минск, Беларусь*

**Аннотация.** Проанализированы метрики успешности краткосрочных численных прогнозов погоды для территории Беларуси на основе мезомасштабной гидродинамической модели атмосферы WRF (Weather Research and Forecasting) с регионально адаптированным блоком моделирования подстилающей поверхности. Оценена эффективность коррекции систематических ошибок численных прогнозов приземных метеопараметров с применением метода экспоненциально взвешенного скользящего среднего и фильтра Калмана.

Предложен метод повышения оправдываемости мезомасштабных численных прогнозов, в котором поправки к прогностическим полям метеопараметров вычисляются с использованием моделей машинного обучения, а предикторами выступают прогнозы нескольких глобальных и региональных гидродинамических моделей атмосферы. Проведен сравнительный анализ эффективности коррекции численных прогнозов с применением моделей машинного обучения (XGBoost и ElasticNet) и рекуррентной графовой нейронной сети с механизмом внимания (TGCN-A).

Показано, что за счет более точного описания в модели WRF подстилающей поверхности и предварительной обработки ее выходной продукции методом экспоненциально взвешенного скользящего среднего оправдываемость численных прогнозов температуры на сроки до 48 ч повышается на 1,0–4,4 %, а среднеквадратическая погрешность скорости ветра уменьшается на 0,1–0,2 м/с. Последующая коррекция прогнозов модели WRF с применением методов машинного обучения и нейронной сети дополнительно повышает оправдываемость численного прогноза температуры в среднем на 3,2 %, а также уменьшает среднеквадратические погрешности прогнозов приземного давления и скорости ветра на 0,20–0,74 гПа и 0,32–0,53 м/с соответственно.

**Ключевые слова:** численный прогноз погоды; мезомасштабная модель; валидация моделей; оправдываемость прогноза; коррекция систематических ошибок; машинное обучение.

**Для цитирования.** Лысенко С. А., Юдыцкая К. С. Коррекция ошибок мезомасштабного численного прогноза погоды методами машинного обучения // Природопользование. – 2025. – № 2. – С. 5–18.

**ERROR CORRECTION OF MESOSCALE NUMERICAL WEATHER FORECAST  
BY MACHINE LEARNING METHODS****S. A. Lysenko, K. S. Yudytskaya***Institute of Nature Management of the National Academy of Sciences of Belarus, Minsk, Belarus*

**Abstract.** The metrics of success of short-term numerical weather forecasts for the territory of Belarus based on the mesoscale hydrodynamic model of the atmosphere WRF (Weather Research and Forecasting) with regionally adapted block of underlying surface modelling are analyzed. The efficiency of systematic error correction of numerical forecasts of surface meteorological parameters using the method of exponentially weighted moving average and Kalman filter is evaluated.

A method of increasing the validity of mesoscale numerical forecasts has been proposed, in which corrections to the prognostic fields of meteorological parameters are calculated using machine learning models, and predictors are forecasts of several global and regional hydrodynamic models of the atmosphere. A comparative analysis of the efficiency of correction of numerical forecasts using machine learning models (XGBoost and ElasticNet) and recurrent graph neural network with attention mechanism (TGCN-A) was carried out.

It is shown that due to a more accurate description of the underlying surface in the WRF model and preliminary processing of its output by the exponentially weighted moving average method, the validity of numerical temperature forecasts for periods up to 48 h increases by 1.0–4.4 %, and the mean square error of wind speed decreases by 0.1–0.2 m/s.

Subsequent correction of WRF model forecasts using machine learning and neural network methods additionally increases the validity of numerical temperature forecasts by 3,2 % on average, and also reduces the RMS errors of surface pressure and wind speed forecasts by 0.20–0.74 hPa and 0.32–0.53 m/s, respectively.

**Keywords:** numerical weather forecast; mesoscale model; model validation; forecast accuracy; correction of systematic errors; machine learning.

**For citation.** Lysenko S. A., Yudytskaya K. S. Error correction of mesoscale numerical weather forecast by machine learning methods. *Nature Management*, 2025, no. 2, pp. 5–18.

**Введение.** Численные прогнозы погоды являются основой современной метеорологии, предоставляя подробные предсказания атмосферных условий на период до 10 дней. Такие прогнозы разрабатываются на основе компьютерных моделей (гидродинамических моделей атмосферы), описывающих физические процессы в атмосфере с учетом текущих метеорологических данных (от метеостанций, метеорологических спутников и зондов). Однако, несмотря на постоянные улучшения моделей, они все еще содержат систематические ошибки и смещения, обусловленные неидеальным описанием атмосферных процессов и подстилающей поверхности, неточными начальными условиями и ограниченными вычислительными ресурсами. В связи с этим необходимым этапом формирования численного прогноза погоды является статистическая обработка (постпроцессинг) выходной продукции гидродинамической модели с учетом ошибок ее прогнозов за некоторый предыдущий период.

В простейшем случае обработка численных прогнозов погоды сводится к коррекции их систематических ошибок для пунктов метеорологических наблюдений с использованием метода экспоненциально взвешенного скользящего среднего или фильтра Калмана [1–3]. В более сложных алгоритмах коррекция численных прогнозов погоды осуществляется с применением методов машинного обучения или нейронных сетей [4, 5].

При известных поправках к прогнозам численной модели для пунктов наблюдений коррекция прогнозных полей приземных метеорологических параметров может осуществляться с применением хорошо отработанных на практике методов объективного анализа, включая методы оптимальной интерполяции и вариационного усвоения данных [6, 7].

В нашем случае целью работы являлось повышение точности прогнозов мезомасштабной численной модели атмосферы WRF (Weather Research and Forecasting) Национального центра атмосферных исследований США (NCAR), применяемой в Беларуси для региональной локализации прогнозов глобальных гидродинамических моделей атмосферы.

Республиканский центр по гидрометеорологии, контролю радиоактивного загрязнения и мониторингу окружающей среды (Белгидромет) разрабатывает ежедневные прогнозы погоды на основе WRF для территории Беларуси. Эти прогнозы в настоящее время не являются официальным прогнозом Белгидромета и носят консультативный характер, поскольку рассчитываются автоматически, без контроля и корректировки специалистом.

Система численного прогноза погоды WRF, используемая в Белгидромете, имеет пространственное разрешение для территории Европы – 15 км и для территории Беларуси – 3 км. Начальные и граничные условия получают из глобальной модели GFS (Global Forecast System) Национального центра прогнозирования состояния окружающей среды США (NCEP). В системе WRF производится ассимиляция данных радиозондирования и результатов наблюдений на метеостанциях [8].

Институтом природопользования НАН Беларуси совместно с Белгидрометом в 2021–2023 гг. реализована ассимиляция в модель WRF данных радиоакустического и микроволнового зондирования (SODAR/RASS) профилей ветра и температуры в пограничном слое атмосферы с детектированием аномалий и коррекцией систематических ошибок в ассимилируемых данных. В 2022 г. в опытную эксплуатацию внедрена разработанная информационная система «Автоматизированный программный комплекс контроля, подготовки и ассимиляции в численную модель прогноза погоды WRF-ARW геофизических данных о подстилающей поверхности по европейской территории», использующая новую цифровую модель подстилающей поверхности, построенную на актуальных данных спутниковых систем наблюдения MODIS, AVHRR и PROBA-V, а также предусматривающая использование оперативных спутниковых данных для уточнения параметров почвенно-растительного покрова – листового индекса, доли поглощаемой фотосинтетически активной радиации, альбедо, снежного покрова и др. Согласно предварительным оценкам, выполненным за зимний период 2022–2023 гг., уточнение параметров подстилающей поверхности на основе спутниковых данных позволило сократить среднеквадратическую погрешность прогноза приземной температуры воздуха для сроков до +48 ч на 0,17–0,31 °C в сравнении с базовым прогнозом WRF [9, 10].

Белгидромет в рамках международного метеорологического консорциума также имеет доступ к выходной продукции некоторых глобальных и региональных систем численного прогнозирования погоды. К ним относятся системы GFS (США), UKMO (Великобритания), ICON (Германия) и COSMO (Россия). В настоящее время данные модели используются в Белгидромете только для ежедневной верификации

краткосрочных численных прогнозов путем их сопоставления с наблюдениями. Одновременно с этим доступ к выходной продукции глобальных моделей открывает возможность для уточнения мезомасштабных прогнозов для территории Беларуси, поскольку поправки к прогностическим полям метеорологических параметров могут вычисляться с использованием моделей машинного обучения, в которых предикторами выступают прогнозы глобальных и региональных гидродинамических моделей атмосферы.

В настоящей работе анализируются метрики успешности прогнозов модели WRF в исходной и модифицированной конфигурации, а также оценивается эффективность применения различных методов постпроцессинга численных прогнозов погоды, включая корректировку систематических погрешностей и комплексирование прогнозов глобальных и региональных моделей методами машинного обучения.

**Коррекция систематических ошибок численных прогнозов погоды.** Первым этапом постпроцессинга выходной продукции численной гидродинамической модели атмосферы является коррекция ее систематических ошибок на основе наблюдений на метеостанциях за некоторый предшествующий период. Для этой цели может использоваться широкий набор известных методов прогнозирования временных рядов – от наиболее простого метода экспоненциально взвешенного скользящего среднего EWMA (Exponentially Weighted Moving Average) до моделей глубокого машинного обучения. Для решения отмеченной задачи нами применены два метода – EWMA и фильтр Калмана, наименее затратные в вычислительном плане и хорошо работающие при наличии пропусков во временных рядах наблюдений или прогнозов.

*Экспоненциально взвешенное скользящее среднее* – это средневзвешенное значение функции в скользящем окне с экспоненциально убывающими весами. EWMA вычисляется по рекурсивной формуле

$$EWMA_t = \alpha p_t + (1 - \alpha) \cdot EWMA_{t-1}, \quad (1)$$

где  $EWMA_t$  – значение экспоненциального скользящего среднего в точке  $t$  (последнее значение, в случае временного ряда);  $\alpha$  – коэффициент сглаживания, характеризующий скорость уменьшения весов (чем меньше его значение, тем больше влияние предыдущих значений на текущую величину среднего);  $p_t$  – значение исходной функции в момент времени  $t$ ;  $EWMA_{t-1}$  – предыдущее значение экспоненциального скользящего среднего.

В решаемой задаче коррекции численных прогнозов приземных метеорологических параметров на территории Беларуси наилучшие результаты показал вариант EWMA с периодом усреднения  $T = 10$  дней и коэффициентом сглаживания  $\alpha = 0,2$ . При этом важно отметить, что коррекцию систематических ошибок производили отдельно для каждой заблаговременности прогноза с учетом предыдущих десяти прогнозов аналогичной заблаговременности.

*Фильтр Калмана* является оптимальным алгоритмом фильтрации параметров динамической линейной системы при наличии неполных и зашумленных наблюдений. Ключевая идея фильтра Калмана в задаче прогноза временных рядов состоит в рекурсивном вычислении поправки к прогнозу модели динамической системы на один шаг вперед с учетом оценок ковариационной матрицы состояния системы и ковариационной матрицы ошибок модели, полученных на предыдущих шагах. Если неопределенность вектора состояния системы выше, чем ошибка модели, то фильтр будет выбирать значения ближе к данным моделирования, в противном случае фильтр будет больше «доверять» оценкам предыдущего состояния системы.

В решаемой нами задаче фильтр Калмана выражает систематическую ошибку прогноза модели  $\hat{\mathbf{x}}_t$  в момент времени  $t$  в виде суммы оценок ошибки прогноза  $\hat{\mathbf{x}}_{t-\Delta t}$  на предыдущем временном шаге  $t - \Delta t$  и шума моделируемой системы  $\mathbf{w}_t$ :

$$\hat{\mathbf{x}}_t = \hat{\mathbf{x}}_{t-\Delta t} + \mathbf{w}_t. \quad (2)$$

Фактическая ошибка прогноза модели  $\mathbf{y}_t$  (разница между наблюдением и прогнозом) включает как систематическую  $\mathbf{x}_t$ , так и случайную  $\mathbf{v}_t$  составляющие:

$$\mathbf{y}_t = \mathbf{x}_{t-\Delta t} + \mathbf{v}_t. \quad (3)$$

Предполагается, что случайные векторы шума системы  $\mathbf{w}_t$  и шума прогноза модели  $\mathbf{v}_t$  независимы и подчиняются нормальному распределению с нулевым математическим ожиданием.

Обновление систематической ошибки прогноза модели с учетом вновь полученного наблюдения выполняется путем прибавления к  $\mathbf{x}_{t-\Delta t}$  вектора невязки прогноза и наблюдения, пропущенного через линейный фильтр Калмана:

$$\hat{\mathbf{x}}_t = \hat{\mathbf{x}}_{t-\Delta t} + \mathbf{K}_t (\mathbf{y}_t - \hat{\mathbf{x}}_{t-\Delta t}). \quad (4)$$

где матрица  $\mathbf{K}_t$ , называемая оптимальной матрицей коэффициентов усиления Калмана, минимизирует среднеквадратичную ошибку  $E[(\hat{\mathbf{x}}_t - \mathbf{x}_t)^2]$ .

Как показано Р. Э. Калманом в работе [2], посвященной рекурсивному решению задачи линейной фильтрации дискретных сигналов, оптимальная матрица коэффициентов усиления в формуле (4) задается следующими выражениями:

$$\mathbf{K}_t = \mathbf{P}_{t/t-\Delta t} \mathbf{H}^T (\mathbf{H} \mathbf{P}_{t/t-\Delta t} \mathbf{H}^T + \mathbf{V}_t)^{-1}, \quad (5)$$

$$\mathbf{P}_{t/t-\Delta t} = \mathbf{P}_{t-\Delta t} \mathbf{W}_t, \quad (6)$$

где  $\mathbf{P}_t$  – оценка матрицы дисперсии вектора систематической ошибки;  $\mathbf{H}$  – матрица наблюдения, которая в нашем случае является единичной матрицей;  $\mathbf{V}_t$  – матрица дисперсий шума наблюдения;  $\mathbf{W}_t = E[\mathbf{w}_t^T \mathbf{w}_t]$  – матрица дисперсий шума системы.

Формулы (4) и (5) показывают, что поправка систематической ошибки прогноза тем значительнее, чем больше дисперсия шума системы и меньше дисперсия шума наблюдения.

Матрица дисперсии систематической ошибки инициализируется до начала процесса фильтрации и далее обновляется на каждом шаге экстраполяции по формуле

$$\mathbf{P}_t = (1 - \mathbf{K}_t \mathbf{H}) \cdot \mathbf{P}_{t/t-\Delta t}. \quad (7)$$

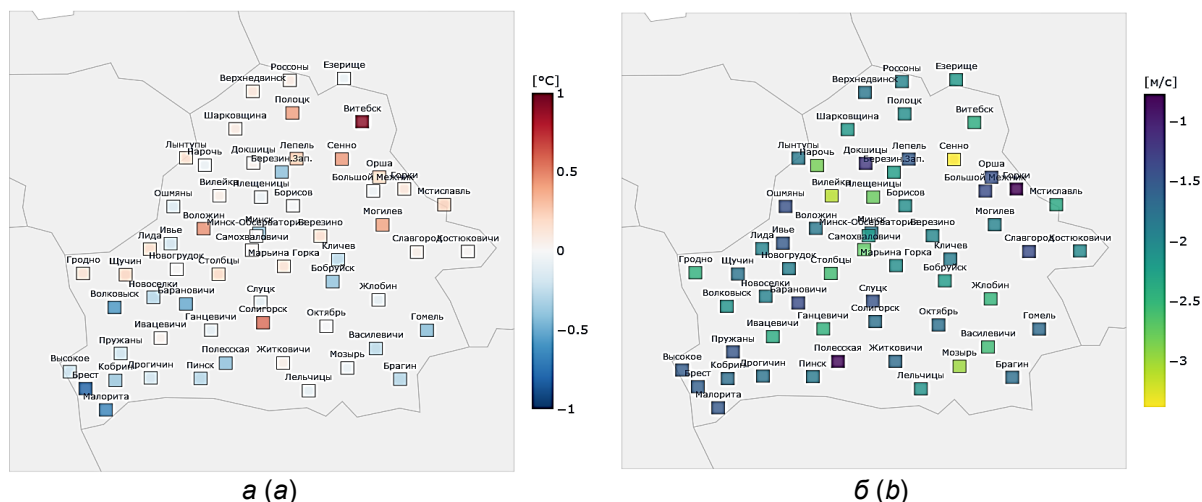
В связи с быстрой сходимостью алгоритма выбор начальных значений  $\hat{\mathbf{x}}_0$  и  $\mathbf{P}_0$  практически не влияет на результаты оценок систематической ошибки прогноза. В то же время результаты работы алгоритма сильно подвержены влиянию матриц  $\mathbf{V}_t$  и  $\mathbf{W}_t$ , характеризующих шум системы и наблюдений. В работах, посвященных применению фильтра Калмана для коррекции численных прогнозов приземной температуры воздуха и скорости ветра, элементы матриц  $\mathbf{V}_t$  и  $\mathbf{W}_t$  предлагается вычислять на основе последних  $N$  полученных оценок  $\mathbf{w}_t = \hat{\mathbf{x}}_t - \hat{\mathbf{x}}_{t-\Delta t}$  и  $\mathbf{v}_t = \mathbf{y}_t - \hat{\mathbf{x}}_t$ . Для их вычисления нами использованы данные наблюдений и прогнозы модели за предыдущие 10 дней.

Основой для валидации численных прогнозов погоды стали данные 60 пунктов метеорологических наблюдений на территории Беларуси и архивы прогнозов гидродинамических моделей атмосферы (глобальных – GFS, UKMO, ICON; региональной – COSMO; мезомасштабной – WRF) за период с 01.03.2023 по 12.09.2025, официально предоставленные Институту природопользования НАН Беларуси Белгидрометом в рамках выполнения этапа освоения результатов НИОК(Т)Р «Разработать, испытать и освоить автоматизированную систему повышения точности численных прогнозов погоды на территории Беларуси на основе модели WRF-ARW с использованием данных спутникового и наземного дистанционного зондирования».

На рис. 1 представлены оценки средних систематических ошибок прогнозов приземной температуры и скорости ветра моделью WRF с пространственным разрешением 3 км на сроки от 6 до 48 ч для 60 метеорологических станций Беларуси. Систематическая ошибка численного прогноза температуры для разных пунктов на территории Беларуси изменяется в диапазоне от  $-1$  °C до  $+1$  °C. Систематическая ошибка численного прогноза не является постоянной, а в зависимости от атмосферных условий, времени года и времени суток может меняться как по величине, так и по знаку. По этой причине коррекция систематических ошибок численного прогноза должна осуществляться каждый раз перед его предоставлением конечным потребителям.

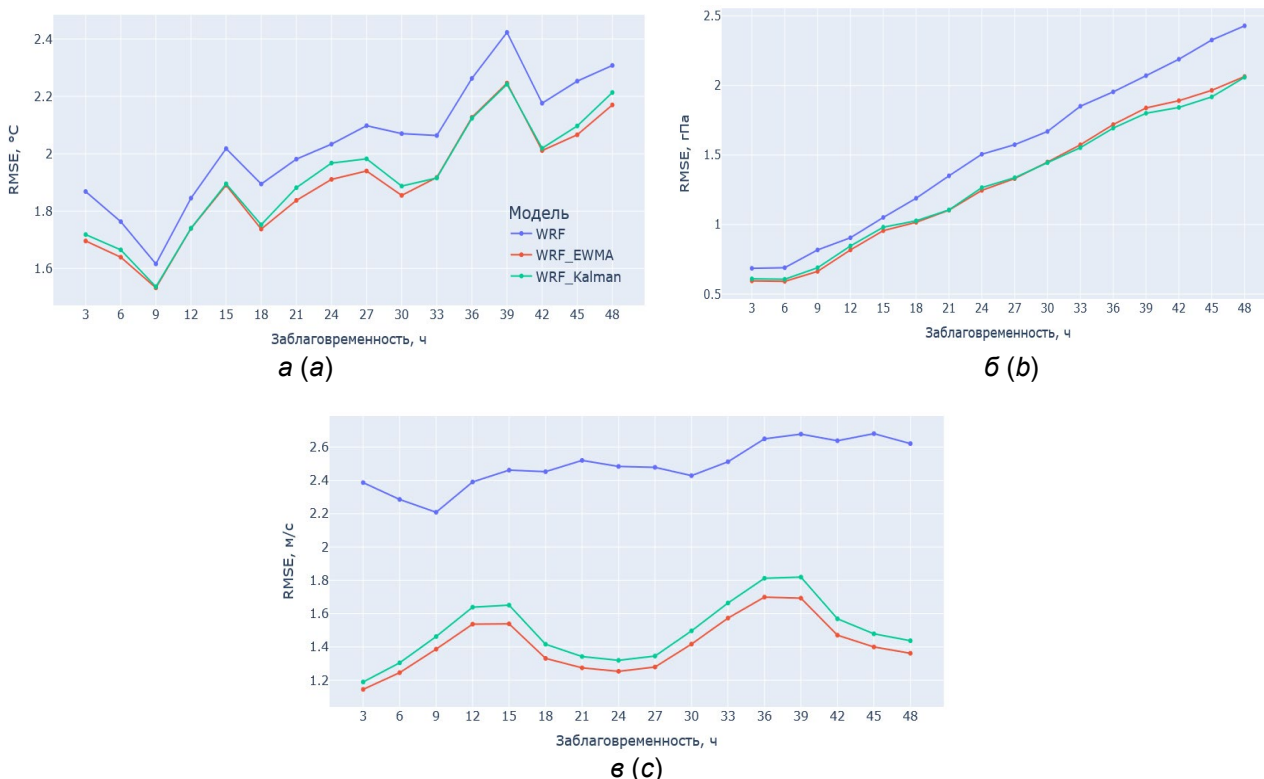
Сопоставление численных прогнозов WRF с наблюдениями также показывает, что данная модель существенно завышает значение скорости ветра на высоте 10 м. На рис. 1, б цветом показана величина средней систематической ошибки краткосрочного численного прогноза скорости ветра на станциях метеорологической сети Республики Беларусь (разница между наблюдением и прогнозом). Средняя величина систематической ошибки прогноза скорости ветра составляет 2,0 м/с, а на отдельных станциях (Сенно, Вилейка, Мозырь) она превышает 3 м/с.

На рис. 2 представлены оценки среднеквадратических ошибок (RMSE) численных прогнозов приземных метеопараметров – температуры, давления и скорости ветра – моделью WRF с разрешением 3 км. Оценки полученные на основе данных всех 60 метеостанций Беларуси и агрегированы в зависимости от заблаговременности прогноза. Расчеты выполнены для случаев, когда для прогноза используются необработанные выходные данные WRF и когда они проходят обработку фильтром Калмана и методом EWMA.



**Рис. 1. Систематические ошибки численных прогнозов приземной температуры (а) и скорости ветра (б) моделью WRF (разрешение 3 км) с заблаговременностью до 48 ч для 60 пунктов метеорологических наблюдений**

**Fig. 1. Systematic errors of numerical forecasts of surface temperature (a) and wind speed (b) by the WRF model (3 km resolution) with a lead time up to 48 hours for 60 meteorological stations**



**Рис. 2. Среднеквадратические ошибки численных прогнозов для территории Беларуси температуры воздуха на высоте 2 м (а), приземного давления (б) и скорости ветра на высоте 10 м (в) в зависимости от заблаговременности прогноза до и после коррекции систематических ошибок фильтром Калмана и методом EWMA (используемая модель – WRF с разрешением 3 км, срок составления прогноза – 00 UTC)**

**Fig. 2. Root-mean-square errors of numerical forecasts for the territory of Belarus of air temperature at 2 m height (a), surface pressure (b) and wind speed at 10 m height (c) as a function of the forecast advance before and after correction of systematic errors by Kalman filter and EWMA method (the model used is WRF with a resolution of 3 km, the forecast time is 00 UTC)**

Исходные численные прогнозы приземных метеопараметров содержат значительную систематическую ошибку, которая различается для разных заблаговременностей. Использование стандартных методов ее коррекции уменьшает RMSE прогноза температуры на величину до 0,22 °С, давления – до 0,36 гПа, скорости ветра – до 1,28 м/с. При этом из двух рассмотренных методов коррекции систематической ошибки лучшие результаты показывает EWMA. В связи с этим данный метод выбран нами в качестве основного метода первичной постобработки численных прогнозов погоды для пунктов метеорологических наблюдений на территории Беларуси.

**Метрики успешности численных прогнозов приземных метеопараметров.** В ходе выполнения проекта по адаптации мезомасштабной модели WRF к территории Беларуси и ассимиляции в нее данных дистанционного зондирования было разработано три экспериментальных варианта системы регионального численного прогнозирования погоды, основанных на модели WRF, которые введены в опытную эксплуатацию в Белгидромете в марте 2023 г. Мезомасштабные прогнозы приземных метеопараметров выпускаются специалистами Белгидромета 2 раза в сутки (в 00 ч и 12 ч UTC) и интерполируются на координаты метеостанций для последующей валидации качества прогнозов. Сопоставление численных прогнозов с данными наблюдений за более чем двухлетний период позволило оценить метрики успешности прогнозов разной заблаговременности.

Валидацию прогнозов проводили для следующих вариантов системы мезомасштабного численного моделирования погоды: WRF\_15 и WRF\_3 – базовая модель WRF в стандартной конфигурации с пространственным разрешением 15 и 3 км соответственно; WRF\_GEO – модель WRF с разрешением 3 км и усовершенствованным блоком моделирования подстилающей поверхности (актуализирована структура землепользования, уточнены пространственные распределения листового индекса, поглощаемой фотосинтетически активной радиации, альbedo почвы и снежного покрова для каждого месяца); WRF\_EXP\_15 и WRF\_EXP\_3 – системы прогнозирования с той же цифровой моделью подстилающей поверхности, что и в WRF\_GEO, но с динамическим уточнением параметров подстилающей поверхности на основе оперативных данных дистанционного зондирования Земли. Прогнозы всех моделей предварительно проходили стадию коррекции систематических ошибок методом EWMA.

Результаты валидации краткосрочных прогнозов модели WRF в пяти ее различных конфигурациях представлены на рис. 3. Для сравнения качества прогнозов использовали среднеквадратическую погрешность (RMSE), полученную по данным 60 пунктов наблюдений на территории Беларуси за период с 01.03.2023 по 12.09.2025.

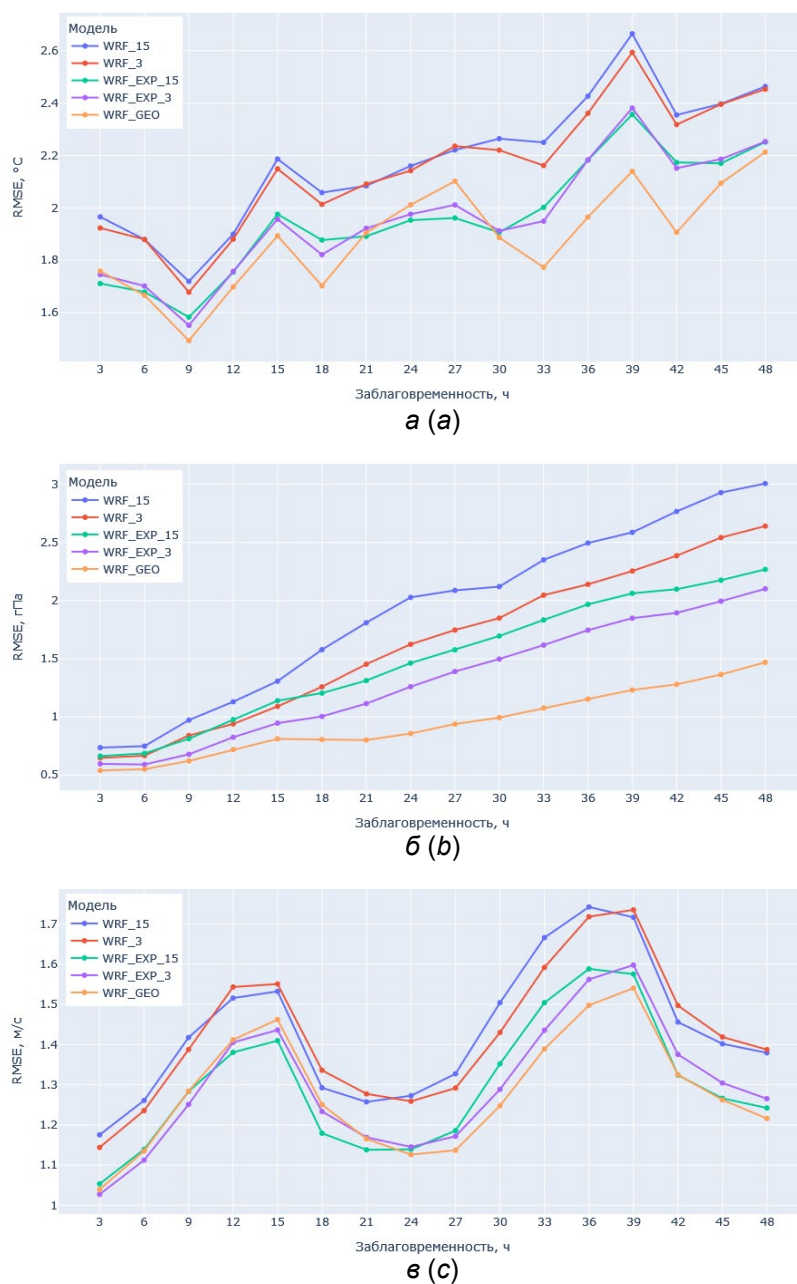
С целью объективного сравнения точности прогнозов моделей для каждого пункта наблюдения производили отбор дат, на которые имеются данные наблюдений и прогнозы всех сравниваемых моделей. Среднеквадратическую погрешность прогноза каждой модели оценивали отдельно для каждой заблаговременности на основании сравнения прогнозов с наблюдениями по всем метеорологическим станциям за весь анализируемый период. Оценку средней оправдываемости прогноза температуры воздуха также производили путем сравнения фактической и спрогнозированной температур на всех станциях за весь анализируемый период. При этом в соответствии с ТКП 17.10-06-2008, если отклонение фактической температуры от прогнозируемой составляло менее 3 °С, то прогноз температуры на заданные дату и час считали оправдавшимся на 100 %, при отклонении 3–4 °С – оправдавшимся на 50 %, при большем отклонении – неоправдавшимся.

По результатам эксперимента сравнения моделей лучшие результаты прогноза приземной температуры показала модель WRF\_GEO. Следующими по точности идут прогнозы WRF\_EXP\_3 и WRF\_EXP\_15. В сравнении с базовыми прогнозами WRF\_15 и WRF\_3 средняя абсолютная ошибка прогноза температуры за счет уточнения параметров подстилающей поверхности уменьшается на величину от 0,2 до 0,7 °С. Оправдываемость прогноза температуры по ТКП на первый день повышается на 1,0–2,5 %, а на второй – на 2,7–4,4 %.

Оценки RMSE мезомасштабных прогнозов приземного давления, представленные на рис. 3, б, отчетливо демонстрируют тенденцию повышения точности численных прогнозов поля давления в результате увеличения пространственного разрешения гидродинамической модели атмосферы и уточнения физических параметров подстилающей поверхности. Явным лидером в прогнозе приземного давления является модель WRF\_GEO с уточненными среднемесячными значениями физических параметров подстилающей поверхности. При этом использование оперативных спутниковых данных для уточнения физических параметров подстилающей поверхности (WRF\_EXP\_3 и WRF\_EXP\_15) не привело к дополнительному повышению точности прогнозов.

Результаты валидации мезомасштабных численных прогнозов также показывают, что увеличение пространственного разрешения модели несущественно сказывается на качестве прогноза поля скорости ветра на высоте 10 м (рис. 3, в). Это обстоятельство, по-видимому, связано с тем, что для мезомасштабного прогнозирования скорости ветра в отдельно взятом регионе первостепенное значение имеет качество исходного прогноза общих синоптических условий, определяющих текущее и будущее

состояния атмосферы. Для прогнозирования глобальной погоды нами использована модель GFS (Global Forecast System) Национального центра прогнозирования окружающей среды (NCEP) США, имеющая пространственное разрешение для территории Беларуси около 22 км. Повышение детальности этого прогноза с применением мезомасштабной модели WRF может достигаться лишь за счет более точного учета физико-географических особенностей региона, а не за счет дальнейшего искусственного увеличения горизонтального разрешения. Это предположение подтверждается оценками RMSE скорости ветра, представленными на рис. 3, в, из которых видно, как уточнение физических параметров подстилающей поверхности сказывается на качестве прогноза: RMSE уменьшается на 0,1–0,2 м/с. Физически это достигается за счет более точного описания в моделях WRF\_GEO, WRF\_EXP\_15 и WRF\_EXP\_3 турбулентных потоков тепла, влаги и импульса с подстилающей поверхности и связанных с ними процессов в атмосферном пограничном слое.



**Рис. 3. Среднеквадратические ошибки численных прогнозов приземной температуры воздуха (а), приземного давления (б) и скорости ветра на высоте 10 м (в) в зависимости от заблаговременности прогноза при разных конфигурациях модели WRF**

**Fig. 3. RMS errors of numerical forecasts of surface air temperature (a), surface pressure (b) and wind speed at a height of 10 m (c) as a function of forecast advance under different WRF model configurations**

В целом по результатам валидации численных прогнозов температуры, давления и скорости ветра можно сделать вывод, что наиболее эффективным вариантом мезомасштабного прогноза погоды для территории Беларуси является прогноз WRF\_GEO. Увеличение пространственного разрешения модели с 15 до 3 км слабо сказывается на ошибках прогноза температуры и скорости ветра, однако повышает точность прогноза приземного давления. Более точное представление в модели WRF подстилающей поверхности позволило повысить оправдываемость прогнозов температуры на срок до 48 ч на 1,0–4,4 %, а также уменьшить среднеквадратические ошибки прогнозов давления и скорости ветра. При этом использование оперативных спутниковых данных для уточнения физических параметров подстилающей поверхности не приводит к повышению точности численных прогнозов погоды по сравнению с использованием средних значений параметров для каждого месяца. Гораздо большее значение для точности мезомасштабных прогнозов WRF имеет качество исходных данных, в частности, качество прогнозов глобальной модели, используемой для задания начальных и граничных условий при решении системы прогностических уравнений термогидродинамики атмосферы.

**Коррекция численных прогнозов погоды методами машинного обучения.** С целью дальнейшего повышения качества выходной продукции мезомасштабной модели WRF предпринята попытка скорректировать ее прогнозы методами машинного обучения. В качестве базового прогноза использовали прогноз WRF\_GEO, показавший наибольшую оправдываемость для большинства сроков. Предикторами поправок к прогнозам WRF\_GEO служили прогнозы глобальных и региональных моделей, к которым Белгидромет имеет доступ в рамках международного метеорологического консорциума: модели ICON (Германия), UKMO (Великобритания), COSMO (Россия) и GFS (США). Помимо этого использовали вспомогательные данные о типе подстилающей поверхности, рельефе и географических координатах пунктов метеорологических наблюдений. Для описания подстилающей поверхности использовали классификацию почвенно-растительного покрова Global Land Cover 2019 (GLC2019) с пространственным разрешением 100 м на основе результатов обработки данных спутникового сканера высокого спектрального разрешения PROBA-V Европейского Космического Агентства.

Поправку к прогнозу WRF\_GEO вычисляли несколькими методами: моделями машинного обучения – XGBoost (градиентный бустинг) и ElasticNet (линейная регрессия с регуляризацией по типу L1 и L2 для обработки мультиколлинеарности предикторов), а также с использованием рекуррентной графовой нейронной сети для обработки временных данных, представленных в виде графа (сеть метеостанций). Целью исследований было сопоставить эффективность коррекции мезомасштабного прогноза погоды с применением современных методов машинного обучения и искусственного интеллекта, а также выработать рекомендации по выбору технологической схемы составления численного прогноза для разных метеопараметров и разной заблаговременности. Ниже дано краткое описание примененных методов.

*Эластичная сеть (ElasticNet)* – это метод регуляризованной регрессии, который устанавливает штрафы (регуляризацию) при выборе весовых коэффициентов перед предикторами по типу L1 (сумма модулей коэффициентов) и L2 (сумма квадратов коэффициентов), что обеспечивает более стабильную и гибкую регрессию. L1-регуляризация обнуляет коэффициенты наименее значимых признаков, что позволяет выполнять автоматический отбор признаков и делает модель более интерпретируемой. L2-регуляризация уменьшает величину коэффициентов, распределяя их влияние на все предикторы, что помогает при наличии сильно коррелированных предикторов.

ElasticNet имеет два основных параметра, которые регулируют баланс между L1 и L2 штрафами:  $\lambda$  – общая сила регуляризации;  $\alpha$  – отношение смеси L1- и L2-регуляризаций. Функция потерь ElasticNet выглядит следующим образом:

$$\min_{\beta_0, \beta} \left( \frac{1}{2N} \sum_{i=1}^N (y_i - \beta_0 - \mathbf{x}_i^T \beta)^2 + \lambda \sum_{j=1}^p \left( \alpha |\beta_j| + \frac{1-\alpha}{2} \beta_j^2 \right) \right), \quad (8)$$

где  $\beta_0$  и  $\beta = (\beta_j)$  – искомые параметры модели, первый из которых является скаляром, а второй – вектором из  $p$  значений;  $N$  – количество наблюдений;  $y_i$  – прогнозируемая переменная;  $\mathbf{x}_i$  – вектор из  $p$  предикторов для  $i$ -го наблюдения. Первый член в выражении (8) – это стандартная сумма квадратов остатков для линейной регрессии; второй – это L1-штраф, который обнуляет коэффициенты; третий – это L2-штраф, который уменьшает коэффициенты.

*XGBoost (Extreme Gradient Boosting)* – это высокоэффективный и масштабируемый алгоритм машинного обучения, основанный на концепции градиентного бустинга. Он использует ансамбль слабых предсказателей, обычно деревьев решений, чтобы создать одну сильную и точную модель. Основная идея бустинга заключается в том, чтобы последовательно обучать новые модели, каждая из которых пытается исправить ошибки, допущенные предыдущими моделями. XGBoost значительно улучшает этот процесс за счет ряда оптимизаций, которые делают его одним из самых популярных и мощных алгоритмов для работы с табличными данными.

В алгоритме XGBoost на каждом шаге  $t$  обучения очередной модели оптимизируется следующая целевая функция:

$$L^{(t)} = \sum_{i=1}^N l\left(\mathbf{y}_i, \hat{\mathbf{y}}_i^{(t-1)} + f_t(\mathbf{x}_i)\right) + \Omega(f_t), \quad (9)$$

где  $l$  – функция потерь (невязка), показывающая насколько хорошо модель соответствует экспериментальным данным;  $\mathbf{y}_i$  и  $\hat{\mathbf{y}}_i^{(t-1)}$  – значение  $i$ -го элемента обучающей выборки и сумма предсказаний первых  $(t - 1)$  моделей соответственно;  $\mathbf{x}_i$  – набор признаков  $i$ -го элемента обучающей выборки;  $f_t$  – модель, которую мы хотим обучить на шаге  $t$ ;  $f_t(\mathbf{x}_i)$  – предсказание  $t$ -й модели на  $i$ -м элементе обучающей выборки;  $\Omega(f_t)$  – функция регуляризации, ограничивающая сложность модели.

Для дерева решений функция

$$\Omega(f_t) = \alpha T + \frac{1}{2} \lambda \|\mathbf{w}\|^2, \quad (10)$$

где  $\alpha$  и  $\lambda$  – параметры регуляризации;  $T$  – количество вершин в дереве;  $\mathbf{w}$  – вектор оценок в листьях дерева.

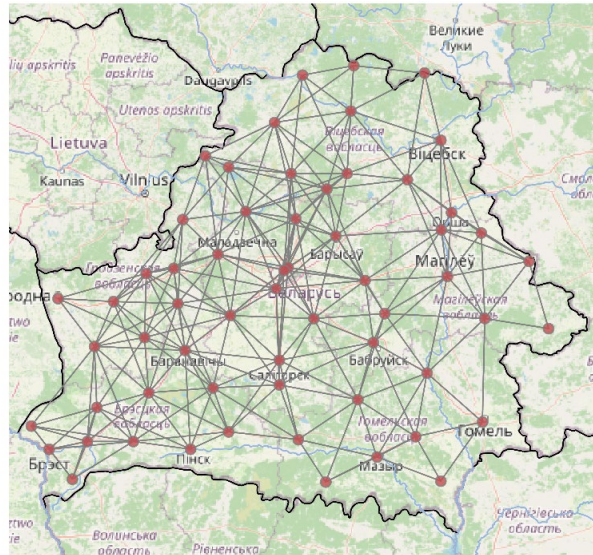
Важными достоинствами моделей ElasticNet и XGBoost по сравнению с нейронными сетями являются их высокая экономичность в плане вычислительных затрат, быстрота обучения и интерпретируемость. В нашем алгоритме коррекции ошибок численных прогнозов погоды эти модели обучаются на скользящем 20-дневном окне, предшествующем моменту составления численного прогноза. При этом для каждой заблаговременности прогноза используется своя отдельная модель ElasticNet или XGBoost, обученная на прогнозах именно этой заблаговременности и данных наблюдений за прошедшие дни. Длина скользящего временного окна, на котором обучаются модели ElasticNet или XGBoost, примерно соответствует теоретическому пределу предсказуемости погоды, когда начальное состояние атмосферы еще не утрачивает влияния на последующее развитие атмосферных процессов.

Учитывая, что значимость данных для обучения моделей падает по мере увеличения интервала  $\Delta t$  между моментом получения и моментом составления прогноза, в алгоритм обучения моделей введен экспоненциальный коэффициент инфляции  $y = \exp(-\Delta t / \tau_0)$ , в котором время затухания  $\tau_0$  выбирают на основе анализа автокорреляционной функции прогнозируемого метеорологического параметра.

Модель *Temporal Graph Convolutional Network with Attention (TGCN-A)* – это гибридная нейросетевая архитектура, предназначенная для совместного улавливания пространственных и временных зависимостей в данных, в частности, для предсказания метеорологических значений на сети станций. Модель интегрирует следующие ключевые компоненты: 1) временные (рекуррентные) графовые свертки (T-GCN) [11] для учета пространственно-временных зависимостей; 2) механизм внимания для взвешивания значимости временных шагов; 3) Residual Connection (обходное соединение) для решения проблемы «исчезающих градиентов» в глубоких нейросетях и улучшения обучения модели.

На рис. 4 показан граф, образованный сетью метеостанций Беларуси. Ребра, соединяющие вершины графа, устанавливают связи между станциями, которые учитывают при корректировке численных прогнозов погоды. Каждому узлу графа присваивают начальное векторное представление (эмбединг) его собственных признаков, включающих прогнозы численных моделей (COSMO, GFS, ICON, UKMO, WRF) на будущий срок и прогнозы за предыдущие 7 дней той же заблаговременности, данные наблюдений на начальный момент прогноза и за предыдущие 7 дней, а также ряд вспомогательных данных: заблаговременность прогноза, день года, час суток, угол склонения, зенитный угол Солнца, долготу, широту и высоту местности, тип подстилающей поверхности в классификации GLC2019.

Ключевым компонентом модели TGCN-A является блок Temporal Graph Convolution (T-GCN), объединяющий спектральную графовую свертку на основе аппроксимирующих фильтров Чебышева и рекуррентную сеть GRU (Gated Recurrent Unit – управляемый рекуррентный блок) для временного моделирования [12]. При обработке каждого нового элемента временной последовательности рекуррентная сеть GRU обновляет свое скрытое состояние, учитывая как новый вход, так и предыдущее состояние. Рекуррентная графовая свертка обновляет представление узла графа, учитывая его непосредственных соседей. С каждым временным шагом узел «видит» все более далеких соседей (как и в обычной графовой свертке), но делает это с помощью механизма, который имеет память и может более избирательно накапливать информацию.



**Рис. 4. Граф станций метеорологической сети:**  
**вершины графа соответствуют метеостанциям, его ребра показывают связи**  
**между станциями, что учитывают при составлении численного прогноза погоды**

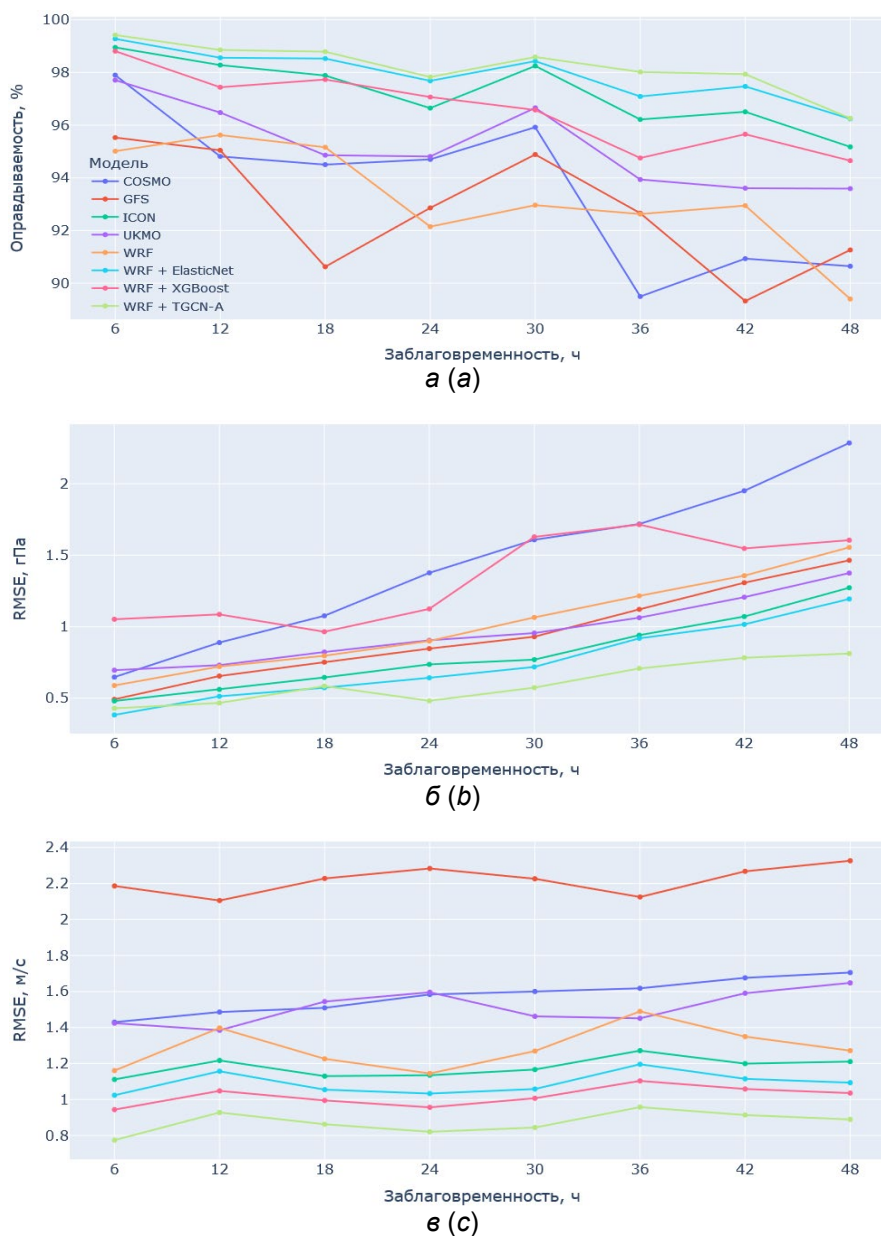
**Fig. 4. Graph of meteorological network stations:**  
**the graph's vertices correspond to the meteorological stations, its edges show the connections**  
**between the stations that are taken into account when compiling a numerical weather forecast**

В дополнение к T-GCN модель TGCN-A использует *механизм внимания (Attention)*, улучшающий работу с длинными временными последовательностями [13]. Вместо единственного скрытого состояния на выходе рекуррентного слоя T-GCN механизм внимания использует взвешенную сумму его скрытых состояний на каждом временном шаге. Для этого каждое скрытое состояние передается в *функцию согласования*, реализованную нами как обычный полносвязный слой с одним выходным узлом и функцией активации  $\tanh$ . Далее к согласованным значениям применяется функция  $\text{softmax}$ , преобразующая их в вероятностное распределение. Полученные вероятности умножаются на скрытые состояния рекуррентного слоя T-GCN и суммируются, чтобы получить вектор контекста, который в нашем случае является вектором поправки к прогнозам численных моделей погоды. Этот вектор прибавляется к прогнозам численных моделей для получения скорректированного прогноза, что реализовано за счет обходного соединения (*Residual connection*), передающего представление узлов графа на выход слоя внимания (*Attention*).

Модель TGCN-A обучалась на всем доступном временном ряду прогнозов и наблюдений на метеостанциях Беларуси с учетом общепринятого деления данных на обучающий, валидационный и тестовый наборы в процентном соотношении 60 : 20 : 20. Обучающие данные используют для непосредственного обучения модели. Валидационные данные позволяют осуществлять контроль переобучения модели путем остановки процесса обучения до того, как модель начнет ухудшать свои показатели. Тестовые данные используют один раз: для финальной оценки качества модели и симуляции ее реальной работы.

Модель TGCN-A разрабатывают отдельно для каждого метеопараметра, что повышает качество прогноза по сравнению с использованием одной универсальной модели с несколькими выходами для разных метеопараметров. На вход модели подается тензор размером  $N \times F \times T$ , где  $N$  – количество метеостанций,  $F$  – количество предикторов метеорологического прогноза,  $T$  – количество прогнозов заданной заблаговременности, учитываемых моделью (7 ретроспективных прогнозов и 1 прогноз на будущий срок).

На рис. 5 представлены оценки метрик успешности численных прогнозов глобальных и региональных моделей (COSMO, GFS, ICON, UKMO), региональной мезомасштабной модели WRF (вариант WRF\_GEO) и гибридов мезомасштабной модели с методами машинного обучения (WRF + ElasticNet, WRF + XGBoost, WRF + TGCN-A). Оценки получены на том же тестовом наборе данных, который используется для контроля качества модели TGCN-A. Стоит отметить, что для моделей ElasticNet и XGBoost не требуется деления данных на обучающие и контрольные, поскольку данные модели обучаются каждый раз заново перед составлением нового прогноза, а метрики их качества оцениваются на новом прогнозе.



**Рис. 5. Метрики успешности прогнозов разных моделей в зависимости от заблаговременности:**  
**а** – оправдываемость численного прогноза температуры воздуха на высоте 2 м;  
**б** и **в** – среднеквадратические погрешности численных прогнозов приземного давления  
и скорости ветра на высоте 10 м соответственно

**Fig. 5. Metrics of success of forecasts of different models depending on the advance:**  
**a** – validity of numerical forecast of air temperature at a height of 2 m;  
**b** and **c** – root-mean-square errors of numerical forecasts of surface pressure  
and wind speed at a height of 10 m, respectively

Как следует из результатов сравнения метрик успешности прогнозов моделей, модель WRF в сочетании с нейросетью TGCN-A является безусловным лидером по оправдываемости прогнозов температуры воздуха: 99,4–97,8 % на первые сутки и 98,6–96,2 % на вторые сутки. Достаточно высокие результаты по оправдываемости прогнозов температуры показывает и вариант WRF с коррекцией ошибок при помощи ElasticNet (наиболее простая ML-модель). При этом вариант прогноза WRF с более сложным методом коррекции ошибок – XGBoost – по оправдываемости прогнозов температуры не превосходит лучшую модель из ансамбля рассматриваемых моделей – ICON (Германия). WRF + XGBoost находится на уровне лучшей модели ансамбля на первые сутки и значительно уступает ей по точности на вторые сутки прогнозного периода. В связи с этим для повышения точности прогнозирования температуры

воздуха на территории Беларуси можно рекомендовать использовать метод коррекции ошибок WRF, основанный на модели машинного обучения ElasticNet или рекуррентной графовой сети TGCN-A.

По точности прогнозов поля давления на территории Беларуси лидирующие позиции также занимают модели WRF + ElasticNet и WRF + TGCN-A, представляющие собой конвейеры регионально адаптированной мезомасштабной гидродинамической модели WRF\_GEO и корректирующих их моделей машинного обучения – ElasticNet или TGCN-A. На первые сутки прогнозного периода прогнозы этих гибридных моделей сопоставимы по точности, на вторые сутки более точной является модель WRF + TGCN-A. С одной стороны, вариант прогноза WRF + XGBoost оказался одним из слабых в ансамбле рассматриваемых моделей. Возможно, это связано с тем, что модель XGBoost является гораздо более сложной по сравнению с моделью ElasticNet и для ее обучения необходимо использовать более длительный период (более 20 дней) или меньший коэффициент временной девальвации обучающих данных. С другой стороны, нейросетевая модель TGCN-A, обученная единожды, позволяет выполнять качественную коррекцию прогнозов давления с учетом всего лишь семи ближайших по времени ретроспективных прогнозов той же заблаговременности. Другим фактором, влияющим на качество обучения модели XGBoost, может являться наличие в ансамбле одной из моделей, которая резко отличается по точности (в худшую сторону) от всех остальных моделей, что далеко не всегда удается выявить на примере 20-дневного ретроспективного периода. Слабый прогноз создает «шум», усложняющий задачу обучения, и увеличивает дисперсию предсказаний ML-модели.

В рейтинге прогнозов моделей по скорости ветра первое место занимает гибридная модель WRF + TGCN-A, имеющая минимальную среднеквадратическую погрешность (RMSE) для всего прогнозного периода. Второе место в этом рейтинге занимает модель WRF + XGBoost, которая по точности прогноза скорости ветра стабильно превосходит все глобальные и региональные гидродинамические модели. Наличие в ансамбле гидродинамических моделей одного члена – модели GFS (США), ошибки прогнозов которого резко отличаются (в худшую сторону) от других моделей, в данном случае не привело к резкому падению точности обучаемой модели XGBoost, что может быть связано с высокой пространственной неоднородностью поля скорости ветра и большим разнообразием для него обучающих примеров по сравнению прогнозами поля давления и температуры.

Таким образом, применение методов машинного обучения для коррекции прогнозов регионально адаптированной мезомасштабной модели WRF позволяет повысить оправдываемость численного прогноза температуры на сроки от 6 до 48 ч в среднем на 3,2 % и уменьшить среднеквадратические погрешности прогнозов приземного давления и скорости ветра на 0,20–0,74 гПа и 0,32–0,53 м/с соответственно.

Следующим этапом постпроцессинга мезомасштабных прогнозов погоды должен стать численный анализ метеорологических полей на предмет усвоения в них уточненных данных для пунктов метеорологических наблюдений. Такой анализ может выполняться, например, с применением метода оптимальной интерполяции или вариационного усвоения данных. Результатом его должны стать скорректированные прогнозные поля приземных метеорологических параметров высокого разрешения, на основе которых можно будет формировать прогноз погоды для любого пункта на территории Беларуси.

**Заключение.** Результаты валидации численных прогнозов погоды на территории Беларуси за период с 01.03.2023 по 12.09.2025 показывают, что среди гидродинамических моделей, к прогнозам которых в настоящее время имеет доступ Белгидромет, наиболее точной по прогнозам температуры, давления и скорости ветра является глобальная модель ICON (Германия).

Прогнозы мезомасштабной региональной модели WRF содержат значительную систематическую ошибку по температуре, которая по ее оценкам для пунктов метеорологических наблюдений изменяется от  $-1$  °C до  $+1$  °C, а также существенно завышают значение скорости ветра – на 1,0–3,5 м/с. Обработка численных прогнозов с применением метода экспоненциально взвешенного скользящего среднего, учитывающего ошибки прогноза модели в предыдущие 10 дней, позволяет практически полностью избавиться от этих систематических ошибок и уменьшить среднеквадратическую ошибку прогноза температуры на величину до 0,22 °C, давления – до 0,36 гПа, скорости ветра – до 1,28 м/с.

Повышение пространственного разрешения модели WRF с 15 до 3 км практически не сказывается на точности прогнозирования температуры и скорости ветра, однако улучшает прогнозы давления. Более существенное влияние на прогнозы WRF оказывает качество цифровой модели подстилающей поверхности для целевого региона. Уточнение физических параметров подстилающей поверхности (листового индекса, альбедо, поглощаемой фотосинтетически активной радиации и др.) с использованием спутниковых данных позволяет повысить оправдываемость прогноза температуры на сроки до 48 ч на 1,0–4,4 % и уменьшить среднеквадратическую погрешность скорости ветра на 0,1–0,2 м/с. Данный эффект достигается за счет более точного описания в модели WRF турбулентных потоков тепла, влаги и импульса в атмосферном пограничном слое.

Для дальнейшего повышения точности мезомасштабных прогнозов погоды предложен алгоритм постпроцессинга при помощи моделей машинного обучения и нейронных сетей, учитывающих текущие прогнозы глобальных и региональных гидродинамических моделей и опыт их прогнозов в предыдущие дни. Применение для этой цели рекуррентной графовой нейронной сети позволяет дополнительно повысить оправдываемость численного прогноза температуры на сроки до 48 ч в среднем на 3,2 % и уменьшить среднеквадратические погрешности прогнозов приземного давления и скорости ветра на 0,20–0,74 гПа и 0,32–0,53 м/с соответственно.

#### Список использованных источников

1. Harvey, A. C. *Time Series Models* / A. C. Harvey. – 2nd ed. – New York : Harvester Wheatsheaf, 1993. – P. 179–198.
2. Kalman, R. E. A new approach to linear filtering and prediction problems / R. E. Kalman // *Journal of Basic Engineering*. – 1960. – Vol. 82. – P. 35–45.
3. Alerskans, E. Local temperature forecasts based on statistical post-processing of numerical weather prediction data / E. Alerskans, E. Kaas // *Meteorological Applications*. – 2021. – Vol. 28, № 4. – 21 p.
4. Быков, Ф. Л. Статистическая коррекция прогнозов погоды по модели COSMO с помощью нейронных сетей / Ф. Л. Быков // *Метеорология и гидрология*. – 2020. – № 3. – С. 5–20.
5. *Statistical Postprocessing for Weather Forecasts: Review, Challenges, and Avenues in a Big Data World* / S. Vannitsem [et al.] // *Bulletin of the American Meteorological Society*. – 2021. – Vol. 102, № 3. – P. E681–E699.
6. Bengtsson, L. *Dynamic Meteorology: Data Assimilation Methods* / L. Bengtsson, M. Ghil, E. Kallen. – New York : Springer-Verlag, 1981. – 330 p.
7. Lorenc, A. C. Analysis methods for numerical weather prediction / A. C. Lorenc // *Quarterly Journal of the Royal Meteorological Society*. – 1986. – Vol. 112. – P. 1177–1194.
8. Формирование продукции систем негидростатического моделирования атмосферы COSMO-RuBy (Гидрометцентр России) и WRF-ARW (Белгидромет) для краткосрочного прогноза погоды / И. А. Розинкина [и др.] // *Гидрометеорологические исследования и прогнозы*. – 2021. – № 4 (382). – С. 6–29.
9. Лысенко, С. А. Оценки влияния подстилающей поверхности на точность численного прогноза температуры воздуха на территории Беларуси с использованием модели WRF / С. А. Лысенко, П. О. Зайко // *Гидрометеорологические исследования и прогнозы*. – 2021. – № 4. – С. 50–68.
10. Лысенко, С. А. Геоинформационная система повышения оправдываемости гидродинамического прогноза погоды для территории Беларуси на основе данных дистанционного зондирования Земли и объективного анализа метеорологических полей / С. А. Лысенко, П. О. Зайко // *Природопользование*. – 2024. – № 1. – С. 30–40.
11. Kipf, T. N. *Semi-Supervised Classification with Graph Convolutional Networks* / T. N. Kipf, M. Welling // *ArXiv preprint*. – 2016. – arXiv:1609.02907.
12. T-GCN: A Temporal Graph Convolutional Network for Traffic Prediction / L. Zhao [et al.] // *IEEE Transactions on Intelligent Transportation Systems*. – 2020. – Vol. 21, № 9. – P. 3848–3858.
13. A3T-GCN: Attention Temporal Graph Convolutional Network for Traffic Forecasting / Bai J. [et al.] // *ISPRS International Journal of Geo-Information*. – 2021. – Vol. 10, № 7. – P. 485.

#### References

1. Harvey A. C. *Time Series Models*. 2nd edition. New York, Harvester Wheatsheaf Publ., 1993, pp. 179–198.
2. Kalman R. E. A new approach to linear filtering and prediction problems. *Journal of Basic Engineering*, 1960, vol. 82, pp. 35–45.
3. Alerskans E., Kaas E. Local temperature forecasts based on statistical post-processing of numerical weather prediction data. *Meteorol. Appl.*, 2021, vol. 28, no. 4, 21 p.
4. Bykov F. L. *Statisticheskaya korrekciya prognozov pogody po modeli COSMO s pomoshch'yu nejronnyh setej* [Statistical correction of weather forecasts based on the COSMO model using neural networks] *Meteorologiya i gidrologiya = Meteorology and Hydrology*, 2020, vol. 3, pp. 5–20. (in Russian)
5. Vannitsem S., Bremnes J. B., Demaeyer J., Evans G., e.a. Statistical Postprocessing for Weather Forecasts: Review, Challenges, and Avenues in a Big Data World. *Bulletin of the American Meteorological Society*, 2021, vol. 102, no. 3, pp. E681–E699.
6. Bengtsson L., Ghil M., Kallen E. *Dynamic Meteorology: Data Assimilation Methods*. New York, Springer-Verlag Publ., 1981, 330 p.
7. Lorenc A. C. Analysis methods for numerical weather prediction. *Quart. J. Roy. Meteor. Soc.*, 1986, vol. 112, pp. 1177–1194.
8. Rozinkina I. A., Rivin G. S., Burak R. N., e.a. *Formirovanie produkciy sistem negidrostaticheskogo modelirovaniya atmosfery COSMO-RuBy (Gidrometcentr Rossii) i WRF-ARW (Belgidromet) dlya kratkosrochnogo prognoza pogody* [Product development of COSMO-RuBy (Hydrometeorological Center of Russia) and WRF-ARW (Belhydromet) non-hydrostatic atmospheric modeling systems for short-term weather forecast]. *Gidrometeorologicheskie issledovaniya i prognozy = Hydrometeorological studies and forecasts*, 2021, vol. 4 (382), pp. 6–29. (in Russian)

9. Lysenko S. A., Zaiko P. O. *Ocenki vliyaniya podstilayushchej poverhnosti na tochnost' chislennogo prognoza temperatury vozduha na territorii Belarusi s ispol'zovaniem modeli WRF* [Estimation of the influence of the underlying surface on the accuracy of the numerical forecast of air temperature in Belarus using the WRF model]. *Gidro meteorologicheskie issledovaniya i prognozy = Hydrometeorological studies and forecasts*, 2021, vol. 4, pp. 50–68. (in Russian)
10. Lysenko S. A., Zaiko P. O. *Geoinformacionnaya sistema povysheniya opravdyvaemosti gidrodinamicheskogo prognoza pogody dlya territorii Belarusi na osnove dannyh distancionnogo zondirovaniya Zemli i ob'ektivnogo analiza meteorologicheskikh polej* [Geoinformation system for improving the accuracy of hydrodynamic weather forecasting for the territory of Belarus based on remote sensing data and objective analysis of meteorological fields]. *Prirodopol'zovanie = Nature Management*, 2024, no. 1, pp. 30–40. (in Russian)
11. Kipf T. N., Welling M. Semi-Supervised Classification with Graph Convolutional Networks. *ArXiv preprint*, 2016, arXiv:1609.02907.
12. Zhao L., Song Y., Zhang C., e.a. T-GCN: A Temporal Graph Convolutional Network for Traffic Prediction. *IEEE Transactions on Intelligent Transportation Systems*, 2020, vol. 21, no. 9, pp. 3848–3858.
13. Bai J., Zhu J., Song Y., e.a. A3T-GCN: Attention Temporal Graph Convolutional Network for Traffic Forecasting. *ISPRS International Journal of Geo-Information*, 2021, vol. 10, no. 7, p. 485.

### Информация об авторах

*Лысенко Сергей Александрович* – доктор физико-математических наук, профессор, директор Института природопользования НАН Беларуси (ул. Ф. Скорины, 10, 220076, г. Минск, Беларусь). E-mail: lysenko.nature@gmail.com

*Юдыцкая Ксения Сергеевна* – младший научный сотрудник, Институт природопользования НАН Беларуси (ул. Ф. Скорины, 10, 220076, г. Минск, Беларусь). E-mail: kseniya.yudytskaya@gmail.com

### Information about the authors

*Sergey A. Lysenko* – D. Sc. (Physical and Mathematical), Professor, Director, Institute of Nature Management of the National Academy of Sciences of Belarus (10, F. Skoriny Str., 220076, Minsk, Belarus). E-mail: lysenko.nature@gmail.com

*Kseniya S. Yudytskaya* – Junior Researcher, Institute of Nature Management of the National Academy of Sciences of Belarus (10, F. Skoriny Str., 220076, Minsk, Belarus). E-mail: kseniya.yudytskaya@gmail.com

---