

# SHORT-TERM WIND SPEED FORECAST BASED ON ARTIFICIAL NEURAL NETWORKS AND THE METHOD OF VARIATIONAL MODE DECOMPOSITION

I. V. Del\*, A. V. Starchenko\*\*

\*Tomsk State University,  
634050, Tomsk, Russia

\*\*V.E. Zuev Institute of Atmospheric Optics SB RAS,  
634055, Tomsk, Russia

---

---

DOI: 10.24412/2073-0667-2025-2-19-32

EDN: VKPBAD

In the current conditions, climate change and the increasing frequency of extreme weather phenomena make the task of wind speed forecasting particularly relevant. In addition, short-term forecasting of local wind speed is extremely important to ensure safe and efficient operation of wind power stations and airports.

Classical forecasting methods based on physical models of atmospheric processes are often inferior in accuracy to machine learning methods. Machine learning methods are able to efficiently process large amounts of data, detecting complex nonlinear dependencies. However, one of the main problems remains the presence of “noise” in the input data. This “noise” caused by external factors such as measurement error, turbulence, changes in temperature, humidity and other meteorological parameters, reduces the accuracy of the constructed models and, as a consequence, negatively affects the forecasting results. To solve this problem, approaches combining machine learning with data preprocessing methods are used. One of the promising directions is the use of artificial neural networks (ANN) combined with input signal filtering.

In this paper, a hybrid method that combines neural networks with the Variational Mode Decomposition (VMD) method has been developed to improve the accuracy of short-term local wind speed prediction. This method allows to decomposed the input signal into several components (variation modes), each of which represents a certain frequency range, thus reducing the influence of noise and increasing the accuracy of useful information extraction. The method of decomposing the input signal into variation modes is applied to the input dataset (hourly measured values of surface wind speed) before using the ANN model for wind speed prediction.

The aim of the work is to develop and apply a hybrid method for short-term prediction of local wind speed with an advance of up to 24 hours, which uses ANN in combination with pre-filtering of the input signal by VMD. Using historical wind speeds measured by a stationary weather station for the previous 24 hours decomposed into modes using the VMD, it is necessary to predict the wind speed in 1, 3, 6, 12 and 24 hours using an ANN.

The ANN architecture is a classical fully connected neural network consisting of three layers: input, hidden and output layers. The size of the input layer is 576 neurons (24 time steps per 24 modes). Each neuron takes a numerical value corresponding to the characteristics of the modes decomposed using the VMD method. The hidden layer of the neural network contains 64 neurons that use the ReLU (Rectified Linear Unit) activation function. The output layer represents a single numerical value — the predicted wind speed in 1, 3, 6, 12 or 24 hours.

The application of the hybrid method has achieved a significant increase in forecasting accuracy. In particular, the Mean Absolute Error (MAE) and Mean Absolute Percentage Error (MAPE) decreased by at least 90 % (to 0.013–0.101 m/s and 0.9 %–6.1 %, respectively) for all considered advance options. The obtained values of the MAE and MAPE metrics confirm the high accuracy of the developed method, since a MAPE of less than 10 % can be classified as excellent prediction. In addition, the hybrid method shows high robustness to changes in data structure, which makes it a versatile tool for dealing with different types of meteorological conditions.

The evaluation of the hybrid method results showed that the use of the VMD combined with ANN not only improves the quality of wind speed prediction, but also opens new opportunities for predicting other meteorological parameters. For example, temperature and humidity time series can also be processed using this approach, which will provide a comprehensive solution to the problems of meteorological analysis. The developed hybrid method for short-term wind speed forecasting is a promising tool that can significantly improve the accuracy of forecasts. Its application is especially relevant in the conditions of growing demand for reliable forecasts necessary to ensure the safety and efficiency of various weather-dependent systems.

Further work in this direction can be aimed at improving the architecture of neural networks used within the method, as well as optimizing the VMD parameters. This will further improve the accuracy and adaptability of the models, which will make them indispensable in a wide range of tasks related to the analysis and forecasting of meteorological data.

**Key words:** artificial neural networks, time series, variational mode decomposition, local short-term wind speed forecast.

## References

1. Huang N. E., Shen Z., Long S. R., et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis // *Proceedings of the Royal Society of London A*. 1998. V. 454. P. 903–995.
2. Torres, M. E., Colominas M. A., Schlotthauer G., Flandrin P. A complete ensemble empirical mode decomposition with adaptive noise // *2011 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. 2011. P. 4144–4147.
3. Gilles J. Empirical Wavelet Transform // *IEEE Transactions on Signal Processing*. 2013. V. 61(16). P. 3999–4010.
4. Singh P., Joshi S. D., Patney R. K., Saha K. The Fourier decomposition method for nonlinear and non-stationary time series analysis // *Proc. R. Soc. A*. 47320160871. 2017. V. 473.
5. Zhou W., Feng Z., Xu Y. F., Wang X., Lv H. Empirical Fourier decomposition: an accurate signal decomposition method for nonlinear and non-stationary time series analysis // *Mech. Syst. Signal Process.* 2022. V. 163.
6. Dragomiretskiy K., Zosso D.. Variational mode decomposition // *IEEE Transactions on Signal Processing*. 2013. V. 62(3). P. 531–544.
7. Lv S., Wang L., Wang S. A Hybrid Neural Network Model for Short-Term Wind Speed Forecasting // *Energies*. 2023. V. 16(4).
8. Zhang Y., Zhao Y., Gao S. A Novel Hybrid Model for Wind Speed Prediction Based on VMD and Neural Network Considering Atmospheric Uncertainties // *IEEE Access*. 2019. V. 7, P. 60322–60332.
9. Gladkih V. A., Makienco V. E. Cifrovaya ul'trazvukovaya meteostanciya // *Pribory*. 2009. V. 7(109). pp. 21–25.
10. Hestenes M. R. Multiplier and Gradient Methods // *Journal of Optimization Theory and Applications*. 1969. V. 4(5). P. 303–320.
11. Rockafellar R. T. A dual approach to solving nonlinear programming problems by unconstrained optimization // *Mathematical Programming*. 1973. V. 5(1). P. 354–373.

- 
12. Bertsekas D. P. Constrained optimization and Lagrange Multiplier methods // Computer Science and Applied Mathematics, Boston: Academic Press. 1982.
  13. Wiener N. Extrapolation, Interpolation, and Smoothing of Stationary Time Series // The MIT Press. 1949.
  14. Goodfellow I., Bengio Y., Courville A. Deep Learning // MIT Press, 2016.
  15. Loshchilov I., Hutter F. Fixing weight decay regularization in adam // arXiv:1711.05101. 2017.
  16. Huber P. J. Robust Estimation of a Location Parameter // Ann. Math. Statist. 1964. V. 35(1). P. 73–101.

# КРАТКОСРОЧНЫЙ ПРОГНОЗ СКОРОСТИ ВЕТРА НА ОСНОВЕ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ С ПРИМЕНЕНИЕМ МЕТОДА ДЕКОМПОЗИЦИИ НА ВАРИАЦИОННЫЕ МОДЫ

И. В. Дель\*, А. В. Старченко\*\*

Томский государственный университет,  
634050, Томск, Россия  
Институт оптики атмосферы СО РАН,  
634055, Томск, Россия

УДК 519.6, 004.032.26

DOI: 10.24412/2073-0667-2025-2-19-32

EDN: VKPBAD

Прогнозирование скорости ветра с использованием нейронных сетей становится все более актуальным в условиях изменения климата и увеличения частоты экстремальных погодных явлений. Кроме того, краткосрочный прогноз локальной скорости ветра чрезвычайно важен для обеспечения безопасной и эффективной работы ветровых электрических станций и аэропортов. Современные методы машинного обучения, включая нейронные сети, способны обрабатывать большие объемы данных и выявлять сложные зависимости, что позволяет значительно повысить точность прогнозов. «Шум» во входных данных, обусловленный различными внешними факторами, часто снижает точность построенных по ним прогнозов, и, как следствие, влияет на производительность и качество математической модели.

Для повышения точности и заблаговременности краткосрочного прогнозирования скорости ветра по измеренным значениям метеорологических параметров за предыдущие часы предложен гибридный метод, который использует искусственные нейронные сети (ИНС) в сочетании с фильтрацией входного сигнала методом декомпозиции на вариационные моды (Variational Mode Decomposition — VMD). Применение разработанного гибридного метода краткосрочного прогноза позволило достичь значительного увеличения точности прогнозирования. В частности, средняя абсолютная ошибка (Mean Absolute Error, MAE) и средняя абсолютная процентная ошибка (Mean Absolute Percentage Error, MAPE) снизились не менее чем на 90 % (до 0.013–0.101 м/с и 0.9 %–6.1 %, соответственно) при рассмотренных вариантах заблаговременности. Полученные значения метрик MAE и MAPE подтверждают высокую точность разработанного метода, поскольку MAPE менее 10 % можно классифицировать как превосходное прогнозирование. Оценивая полученные результаты, можно сделать вывод о целесообразности дальнейшей работы по использованию предложенного гибридного метода для повышения качества краткосрочного прогнозирования скорости ветра и других метеопараметров, получаемых в результате наблюдений.

**Ключевые слова:** искусственные нейронные сети, временные ряды, вариационная модовая декомпозиция, краткосрочный локальный прогноз скорости ветра.

**Введение.** Прогнозирование временных рядов, включая метеорологические данные, представляет собой сложную задачу, требующую точных и надежных методов. В этом

контексте искусственные нейронные сети (ИНС) уже зарекомендовали себя как мощный инструмент. В последнее время для повышения уровня точности прогноза с помощью ИНС все больше внимания уделяется методам предварительной обработки сигналов. Одним из таких подходов является метод декомпозиции на вариационные моды, который эффективно разлагает сложные сигналы на более простые компоненты, существенно облегчая их анализ и обработку с помощью ИНС.

Существует множество различных методов предварительной обработки сигналов. Например, такие как: Empirical Mode Decomposition (EMD) [1] — метод декомпозиции на эмпирические моды, Complete Ensemble Empirical Mode Decomposition with Adaptive Noise (CEEMDAN) [2] — ансамблевая вариация метода декомпозиции на эмпирические моды с добавлением адаптивного шума, Empirical wavelet transform (EWT) [3] — эмпирическое вейвлет преобразование, Fourier decomposition method (FDM) [4] — метод декомпозиции Фурье, Empirical Fourier Decomposition (EFD) [5] — эмпирическое разложение Фурье, VMD [6] — метод декомпозиции на вариационные моды.

VMD [6] предлагает хороший компромисс между сложностью реализации и эффективностью разложения сигнала, что делает его пригодным для широкого спектра приложений. Хотя CEEMDAN [2] может быть более устойчив к шумам, VMD также обеспечивает достаточную устойчивость к возмущениям и, в отличие от EMD [1], более прост в реализации. По сравнению с EWT [3], FDM [4], преимуществом VMD является лучшая обработка нестационарных сигналов с близко расположенными частотами.

Пример успешного применения гибридных методов в прогнозировании скорости ветра можно найти в работе [7]. Авторы этой работы эффективно сочетают метод декомпозиции на вариационные моды, рекуррентную нейронную сеть Gated Recurrent Unit (GRU) и метод поиска по сетке с перекрестной проверкой (Grid Search with Rolling Crossvalidation — GSRCV) для одновременной оптимизации ключевых параметров VMD и GRU. Достигнутые результаты (среднеквадратичная ошибка RMSE: 0.2047, средняя абсолютная ошибка MAE: 0.1435, средняя абсолютная процентная ошибка MAPE: 3.77 %, симметричная средняя абсолютная процентная ошибка SMAPE: 3.74 %, заблаговременность — 1 час) демонстрируют высокую конкурентоспособность предложенной гибридной модели среди современных подходов к прогнозированию скорости ветра. Кроме того, было отмечено, что VMD превосходит другие методы декомпозиции, такие как EMD и EEMD, в плане точности прогнозирования, что подчеркивает его эффективность в подобных задачах.

В статье [8] предложена гибридная модель прогнозирования скорости ветра, основанная на методе декомпозиции на вариационные моды, ИНС и системе Лоренца для учета атмосферных неопределенностей. Сначала данные скорости ветра обрабатываются с помощью VMD, чтобы выделить несколько частотных компонент, затем компоненты используются для построения и обучения нейронной сети (например, нейронная сеть с долгой краткосрочной памятью — LSTM, полносвязная нейронная сеть — FCNN, сеть радиально-базисных функций — RBF или рекуррентная нейронная сеть Элмана), а система Лоренца применяется для учета хаотической природы атмосферных возмущений. Гибридная модель продемонстрировала значительное улучшение точности прогнозирования (заблаговременность — 1 час), особенно заметное снижение MAE (менее 0.07) и MAPE (менее 2 %), что подтверждает эффективность учета атмосферных неопределенностей и использования метода декомпозиции на вариационные моды.

Целью работы является разработка и применение гибридного метода для краткосрочного прогнозирования локальной скорости ветра с заблаговременностью до 24 часов, ко-




Рис. 1. Изменение скорости ветра в районе УЗМ БЭК с 01.01.2021 по 31.10.2022

торый использует ИНС в сочетании с предварительной фильтрацией входного сигнала методом декомпозиции на вариационные моды. По измеренным стационарной метеостанцией историческим значениям скорости ветра за предыдущие часы, разложенным на моды с помощью VMD, необходимо с помощью ИНС предсказать скорость ветра через 1, 3, 6, 12 и 24 часа.

**1. Структура входных данных.** Исходные метеорологические данные для исследования были получены с помощью ультразвуковой метеостанции (УЗМ) «Метео-2» Базового экспериментального комплекса (БЭК) ИОА СО РАН за период времени с 01.01.2021 по 31.10.2022. Автоматизированный ультразвуковой метеорологический комплекс «Метео-2» предназначен для измерения метеорологических параметров воздушной среды: температуры ( $\pm 0.35^\circ$ ), скорости ( $\pm 0.3$  м/с) и направления ( $\pm 3^\circ$ ) ветра, относительной влажности, атмосферного давления [9].

Размер набора данных составляет 16056 ежечасных наблюдений. Изменение скорости ветра в районе УЗМ БЭК показано на рис. 1. Максимальная скорость ветра за весь рассматриваемый период составила 9.7 м/с, среднее значение скорости ветра — 2.3 м/с. Выбранные данные были разделены на три независимые выборки: обучающую выборку, соответствующую 70 % данных от основной выборки, валидационную выборку, соответствующую 20 %, и тестовую выборку, соответствующую 10 %.

В данной работе метод декомпозиции входного сигнала на вариационные моды (VMD) применяется к входному набору данных (ежечасно измеренным значениям приземной скорости ветра) перед использованием модели ИНС для прогнозирования скорости ветра.

**2. Метод декомпозиции на вариационные моды.** В [6] предложен нерекурсивный метод VMD, в котором моды извлекаются одновременно. Метод ищет ансамбль мод и соответствующие им центральные частоты таким образом, чтобы моды после сглаживания в совокупности воспроизводили входной сигнал.

Метод VMD может разложить любой входной сигнал  $y(t)$  на дискретное количество составляющих ( $k$ -моды), где требуется, чтобы каждая мода (подсигналы)  $u_k$  представлялась центральной частотой  $\omega_k$ , определенной в процессе декомпозиции. Каждая мода

рассматривается как амплитудно-модулированный и частотно-модулированный (АМ-ЧМ) сигнал вида

$$u_k(t) = A_k(t) \cos(\phi_k(t)),$$

где  $A_k(t)$  и  $\omega_k(t)$  — мгновенная амплитуда и мгновенная частота функции  $u_k(t)$ ,  $\omega_k(t) = \frac{d\phi_k(t)}{dt}$ .

Ограниченная вариационная задача для нахождения всех мод в VMD определяется как [6]:

$$\min_{u_k, \omega_k} \left\{ \sum_k \left\| \partial_t \left[ \left( \delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \quad \text{при условии} \quad \sum_k u_k(t) = y(t), \quad (1)$$

где  $y(t)$  обозначает сигнал для разложения;  $u_k(t) \in \{u_1(t), u_2(t), \dots, u_K(t)\}$  —  $k$ -я мода;  $\omega_k \in \{\omega_1, \omega_2, \dots, \omega_K\}$  — центральная частота  $k$ -й моды;  $\delta(t)$  — распределение Дирака;  $t$  — время;  $K$  — количество мод;  $*$  обозначает свертку;  $e^{-j\omega_k t}$  — фазор, описывающий вращение комплексного сигнала во времени, где  $j^2 = -1$ . Более высокие значения  $k$  соответствуют модам с компонентами более низкой частоты.

Вариационная задача в VMD [6] (1) эффективно решается с помощью метода множителей альтернативного направления (Alternating Direction Method of Multipliers — ADMM [10–12]). Моды  $u_k(t)$  обновляются с помощью фильтрации Винера в области Фурье с фильтром, настроенным на текущую центральную частоту [13]:

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{y}(\omega) - \sum_{i < k} \hat{u}_i^{n+1}(\omega) - \sum_{i > k} \hat{u}_i^n(\omega) + 0.5\hat{\lambda}^n(\omega)}{1 + 2\theta(\omega - \omega_k^n)^2}, \quad (2)$$

где  $\hat{u}_k(\omega)$ ,  $\hat{y}(\omega)$ ,  $\hat{\lambda}(\omega)$  — преобразования Фурье соответствующих величин,  $n$  — номер итерации,  $\theta > 0$  — коэффициент при квадратичном штрафном члене,  $\lambda$  — множитель Лагранжа.

Затем центральные частоты  $\omega_k$  обновляются как центр тяжести спектра мощности соответствующей моды:

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |\hat{u}_k^{n+1}(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k^{n+1}(\omega)|^2 d\omega}. \quad (3)$$

Наконец, множитель Лагранжа  $\lambda$ , обеспечивающий выполнение точных ограничений, на следующей итерации вычисляется как:

$$\hat{\lambda}^{n+1}(\omega) = \hat{\lambda}^n(\omega) + \tau \left( \hat{y}(\omega) - \sum_k \hat{u}_k^{n+1}(\omega) \right), \quad (4)$$

где  $\tau \geq 0$  — итерационный коэффициент.

Итерационная процедура (2)–(4) повторяется до тех пор, пока не будет выполнено условие сходимости [6]:

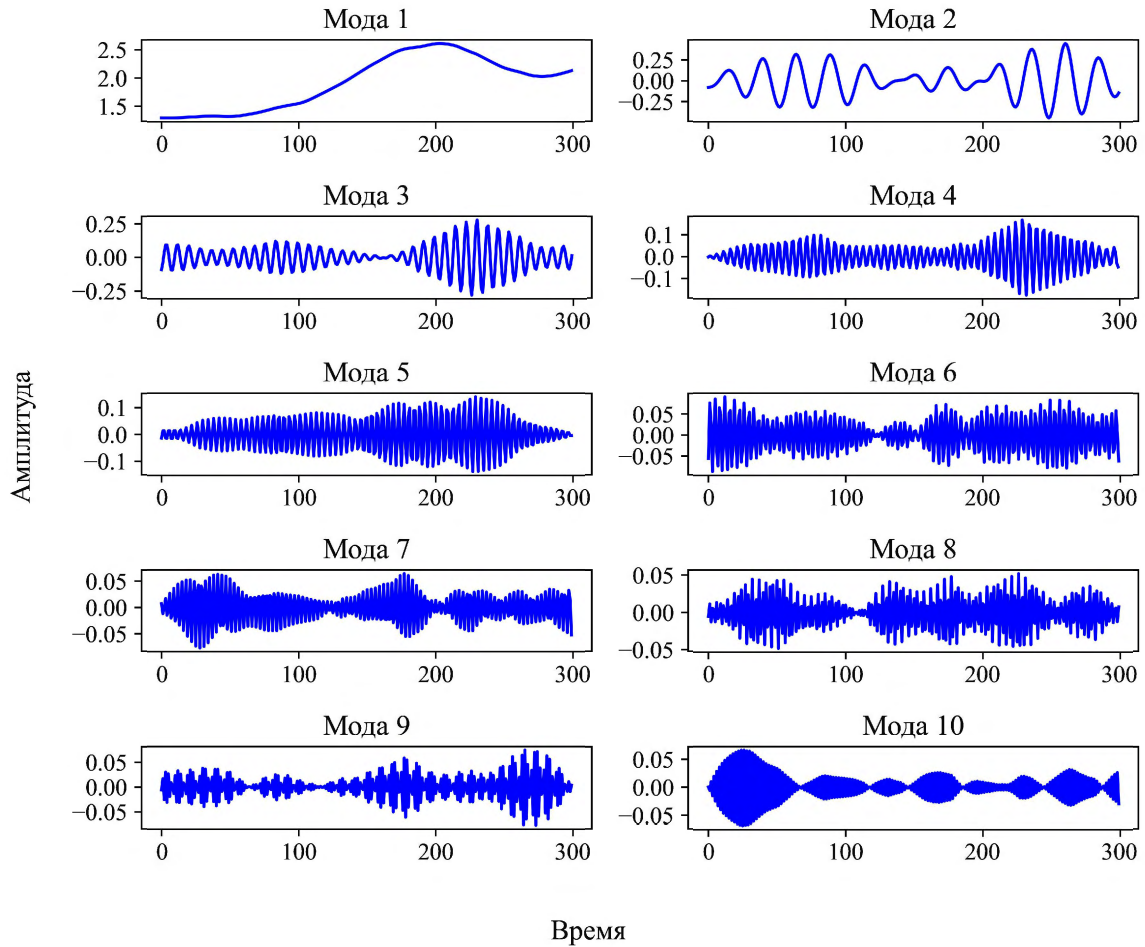


Рис. 2. Моды  $u_1(t), \dots, u_{10}(t)$ , разложенные с помощью VMD

$$\sum_k \frac{\|\hat{u}_k^{n+1} - \hat{u}_k^n\|_2^2}{\|\hat{u}_k^n\|_2^2} < \varepsilon,$$

где  $\varepsilon > 0$  — порог сходимости, определяющий критерий остановки алгоритма при достижении необходимой точности.

На эффективность разложения VMD влияют выбираемое количество разложений (мод)  $K$ , величина  $\theta$ , порог сходимости  $\varepsilon$  и значение  $\tau$ . В данном исследовании все параметры подбирались эмпирически. Эксперименты проводились на разных уровнях декомпозиции: от 2 до 30, с шагом 3. В каждом случае моды интегрируются в оптимизированную ИНС для прогнозирования скорости ветра и проводится оценка значений выбранных метрик.

На основе проведенного эксперимента предложены следующие параметры VMD:  $K = 24$ ,  $\theta = 100$ ,  $\varepsilon = 10^{-9}$ . На рис. 2 представлены первые 10 мод, разложенных с помощью VMD. Для иллюстрации результатов используются первые 400 наблюдений.

**3. Архитектура нейронной сети.** Архитектура нейронной сети представляет собой классическую полносвязную сеть (Fully Connected Neural Network — FCNN), состоящую из трех слоев: входного, скрытого и выходного слоев. Размер входного слоя — 576 нейронов (24 временных шага на 24 моды). Каждый нейрон принимает числовое значение, соответ-

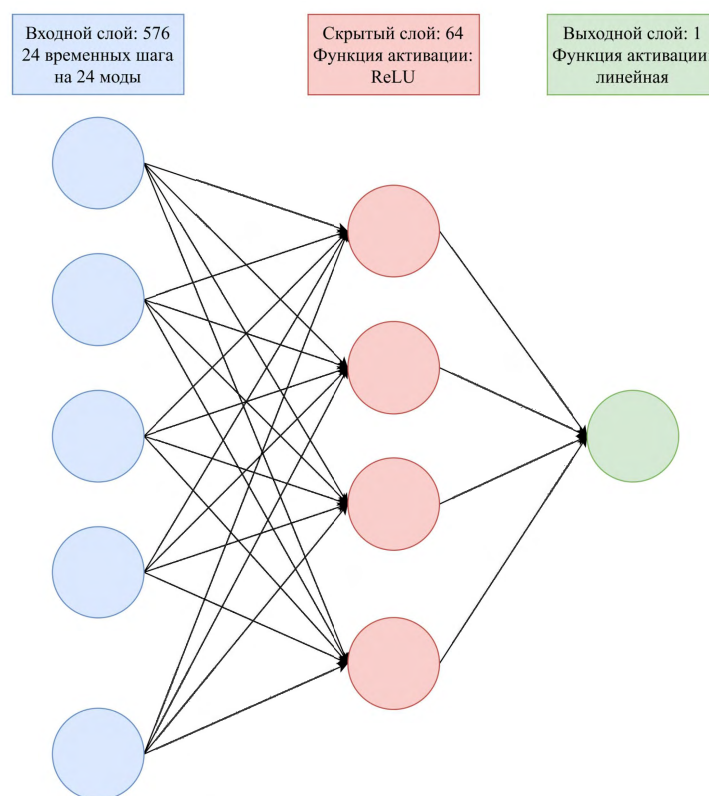


Рис. 3. Архитектура нейронной сети

ствующее характеристикам мод, разложенных с помощью метода VMD. Скрытый слой нейронной сети содержит 64 нейрона, которые используют кусочно-линейную функцию активации ReLU (Rectified Linear Unit) [14], которая позволяет модели учитывать только положительные значения, что улучшает обучение и позволяет избежать проблем с затуханием градиента функции потерь (когда градиенты целевой функции становятся очень малыми, затрудняя дальнейшее обучение). Выходной слой представляет одно числовое значение — прогнозируемую скорость ветра через 1, 3, 6, 12 или 24 часа.

Оптимальное количество скрытых слоев и нейронов было получено экспериментально, путем изменения архитектуры сети и запуска процесса обучения до получения хорошей производительности.

В рамках исследования были протестированы и другие архитектуры нейронных сетей, такие как Convolutional Neural Network (CNN), GRU и LSTM, однако представленная на рис. 3 архитектура FCNN с одним скрытым слоем и функцией активации ReLU продемонстрировала наименьшую ошибку, обеспечивая более высокую точность прогнозирования и лучшую вычислительную производительность.

В рассматриваемой нейронной сети оптимальный поиск весовых коэффициентов осуществляется методом адаптивной инерции с коррекцией весовых коэффициентов путем добавления L2-регуляризации AdamW [15]. В качестве функции потерь использовалась функция Хьюбера [16] — комбинация среднеквадратичной ошибки при малых погрешностях и средней абсолютной ошибки при больших:

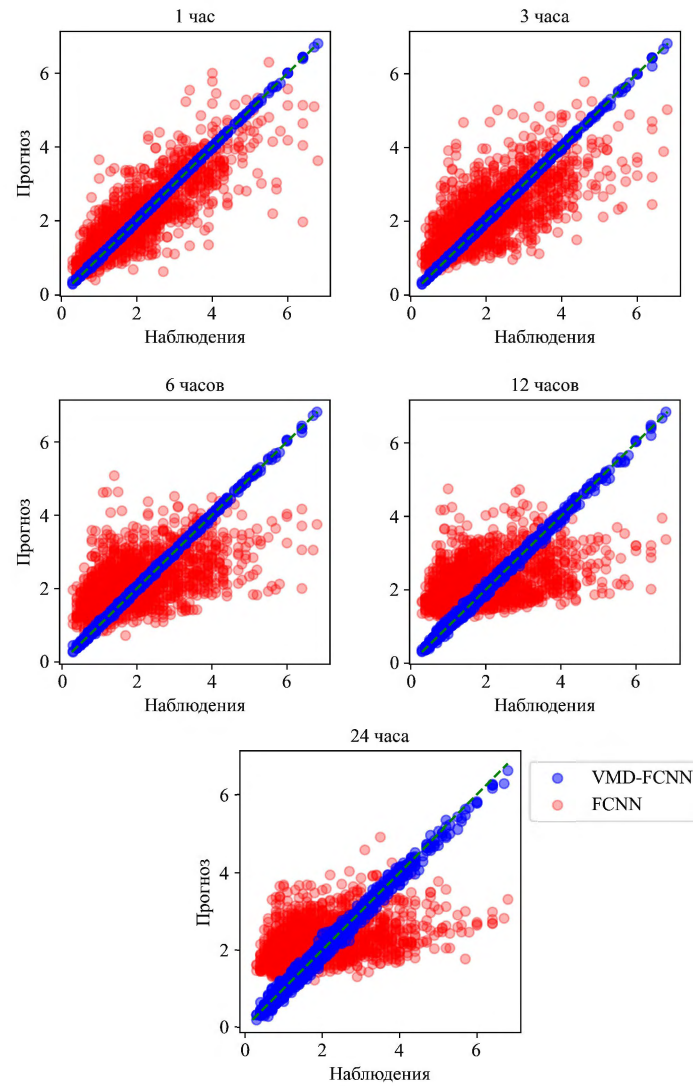


Рис. 4. Соответствие прогнозов моделей и наблюдений с различной заблаговременностью (1, 3, 6, 12 и 24 часа вперед)

$$\text{Huber}(p, o) = \begin{cases} \frac{1}{2}(p - o)^2, & \text{если } |p - o| \leq \delta, \\ \delta |p - o| - \frac{1}{2}\delta^2, & \text{если } |p - o| > \delta. \end{cases}$$

Здесь  $o$  — наблюдения, а  $p$  — предсказанные значения,  $\delta = 2\text{м/с}$ .

Сеть обучалась за фиксированное количество эпох, равное 100. Размер пакета при обучении сети выбирался равным 128.

3.1. *Метрики оценивания.* Для оценки качества прогнозирования скорости ветра рассматривались следующие метрики:

$$\text{MAE} = \frac{1}{m} \sum_{i=1}^m |o_i - p_i|, \quad \text{MAPE} = \frac{100\%}{m} \sum_{i=1}^m \left| \frac{o_i - p_i}{o_i} \right|, \quad \text{R}^2 = 1 - \frac{\sum_{i=1}^m (o_i - p_i)^2}{\sum_{i=1}^m (o_i - \bar{o})^2},$$

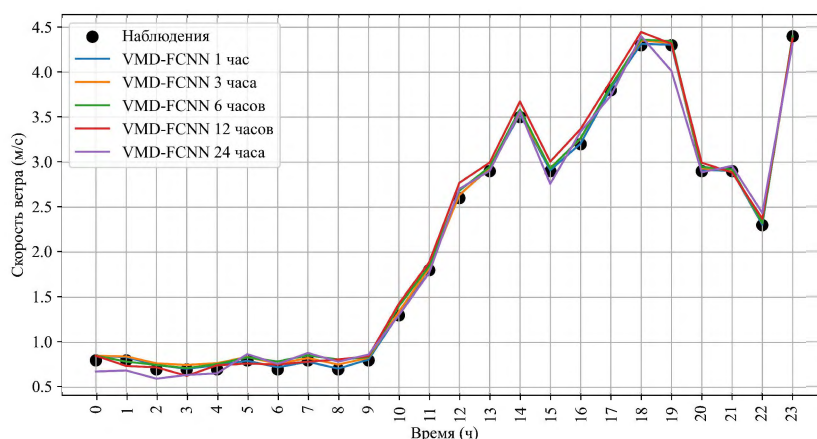


Рис. 5. График скользящего прогноза на 03.09.2022 с заблаговременностью 1, 3, 6, 12 и 24 часа




Рис. 6. График скользящего прогноза на 23.10.2022 с заблаговременностью 1, 3, 6, 12 и 24 часа

где  $o_i$  — наблюдения, а  $p_i$  — предсказанные значения;  $\bar{o}$  — среднее значение. MAE — это средняя абсолютная ошибка, MAPE — средняя абсолютная процентная ошибка,  $R^2$  — коэффициент детерминации.

MAE показывает среднее абсолютное отклонение прогнозируемых значений от фактических значений (всегда имеет те же единицы измерения, что и прогнозируемая величина). MAPE выражает среднюю ошибку модели от фактического значения в процентах. Это полезная метрика, когда важна нормализация ошибки и необходимо учитывать относительные величины ошибок. Практические значения MAPE: 0–10 % — высокая точность прогнозов; 10–20 % — приемлемая точность для большинства задач; 20–50 % — средний уровень точности; возможно, модель нуждается в доработке; >50 % — низкая точность прогноза, требуются серьезные улучшения модели или данных.  $R^2$  измеряет, насколько хорошо модель объясняет изменчивость (вариацию) реальных данных: если  $R^2 = 1$ , то модель идеально объясняет все изменения реальных данных (ошибка = 0); если  $R^2 = 0$ , то модель не объясняет данные лучше, чем простое среднее значение; если  $R^2 < 0$ , то модель хуже, чем использование среднего значения в качестве прогноза.

Таблица 1

Метрики прогноза скорости ветра с различной заблаговременностью

	VMD-FCNN			FCNN		
	MAE, м/с	MAPE	R <sup>2</sup>	MAE, м/с	MAPE	R <sup>2</sup>
<b>1 час</b>	0.013	0.9 %	0.999	0.446	27 %	0.688
<b>3 часа</b>	0.018	1.1 %	0.999	0.599	39 %	0.471
<b>6 часов</b>	0.027	1.8 %	0.998	0.727	50 %	0.261
<b>12 часов</b>	0.051	3.2 %	0.996	0.861	61 %	0.062
<b>24 часа</b>	0.101	6.1 %	0.986	1.062	72 %	0.013

3.2. *Результаты прогнозирования.* Для оценки эффективности предложенного гибридного метода в табл. 1 приведены значения метрик для прогноза скорости ветра с различной заблаговременностью (1, 3, 6, 12 и 24 часа вперед), рассчитанные по 24 измеренным значениям для предложенного гибридного метода и полносвязной нейронной сети без применения технологии VMD.

При сравнении полученных значений метрик можно сделать вывод, что предлагаемый гибридный метод значительно уменьшает ошибку прогнозирования ИНС. Из таблицы также видно, что точность прогнозирования в каждом случае снижается с увеличением величины периода прогнозирования, причем при использовании разработанного гибридного метода прогнозирования характер снижения гораздо меньше.

Метрики прогноза с заблаговременностью 1 час, полученные в рамках данного исследования, демонстрируют соизмеримую точность с результатами, представленными в [7, 8].

На рис. 4 приведены графики соответствия прогнозируемых и фактических значений скорости ветра с разной заблаговременностью. Видно, что во всех рассмотренных случаях гибридный метод хорошо соответствует идеальному прогнозу.

При прогнозировании с использованием гибридного метода наблюдается значительное улучшение показателей качества по сравнению с моделью полносвязной нейронной сети без применения технологии VMD. В частности, при заблаговременности 1 час средняя абсолютная ошибка (MAE) и средняя абсолютная процентная ошибка (MAPE) уменьшились на 97 %, коэффициент детерминации (R<sup>2</sup>) увеличился на 31 %. При заблаговременности 6 часов MAE и MAPE снизились на 96 %, R<sup>2</sup> повысился на 74 %. Наконец, при заблаговременности 24 часа MAE и MAPE снизились не менее чем на 90 %, R<sup>2</sup> достигло увеличения на 99 %. Снижение MAE и MAPE означает, что гибридная модель дает более точные предсказания и допускает гораздо меньше ошибок. Увеличение R<sup>2</sup> говорит о том, что модель все лучше описывает реальную зависимость между предикторами и целевой переменной. Эти результаты подтверждают преимущество использования предложенного гибридного метода для прогнозирования с различной заблаговременностью.

На рис. 5 и 6 приведены иллюстрации согласования прогноза и измерений для некоторых дат тестовой выборки с заблаговременностью 1, 3, 6, 12 и 24 часа. Графические данные однозначно подтверждают преимущество использования предложенного гибридного метода для прогнозирования с различной заблаговременностью, демонстрируя его стабильную эффективность.

**Заключение.** В данной работе предложен гибридный метод краткосрочного прогноза локальной приземной скорости ветра на основе данных наблюдений на метеостанциях. Метод основан на использовании вариационной декомпозиции временного ряда измерений


на моды и последующего применения совокупности мод к модели полносвязной нейронной сети для получения прогнозируемой скорости ветра через заданное число часов.

Применение разработанного гибридного метода краткосрочного прогноза позволило в лучшем случае уменьшить МАЕ и МАРЕ на 97 % для заблаговременности 1 час,  $R^2$  увеличить на 99 % для заблаговременности 24 часа. В частности, значения МАЕ снизились до 0.013–0.101 м/с, а МАРЕ — до 0.9 %–6.1 % в рассмотренных сценариях, что соответствует высокой точности прогнозирования.

Оценивая полученные результаты, можно сделать вывод о целесообразности дальнейшей работы по использованию предложенного гибридного метода для повышения качества краткосрочного прогнозирования скорости ветра и других метеопараметров, получаемых в результате наблюдений.

## Список литературы

1. Huang N. E., Shen Z., Long S. R., et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis // *Proceedings of the Royal Society of London A*. 1998. V. 454. P. 903–995.
2. Torres, M. E., Colominas M. A., Schlotthauer G., Flandrin P. A complete ensemble empirical mode decomposition with adaptive noise // *2011 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. 2011. P. 4144–4147.
3. Gilles J. Empirical Wavelet Transform // *IEEE Transactions on Signal Processing*. 2013. V. 61(16). P. 3999–4010.
4. Singh P., Joshi S. D., Patney R. K., Saha K. The Fourier decomposition method for nonlinear and non-stationary time series analysis // *Proc. R. Soc. A*. 47320160871. 2017. V. 473.
5. Zhou W., Feng Z., Xu Y. F., Wang X., Lv H. Empirical Fourier decomposition: an accurate signal decomposition method for nonlinear and non-stationary time series analysis // *Mech. Syst. Signal Process.* 2022. V. 163.
6. Dragomiretskiy K., Zosso D. Variational mode decomposition // *IEEE Transactions on Signal Processing*. 2013. V. 62(3). P. 531–544.
7. Lv S, Wang L, Wang S. A Hybrid Neural Network Model for Short-Term Wind Speed Forecasting // *Energies*. 2023. V. 16(4).
8. Zhang Y., Zhao Y., Gao S. A Novel Hybrid Model for Wind Speed Prediction Based on VMD and Neural Network Considering Atmospheric Uncertainties // *IEEE Access*. 2019. V. 7, P. 60322–60332.
9. Гладких В. А., Макиенко В. Э. Цифровая ультразвуковая метеостанция // *Приборы*. 2009. № 7, (109). С. 21–25.
10. Hestenes M. R. Multiplier and Gradient Methods // *Journal of Optimization Theory and Applications*. 1969. V. 4(5). P. 303–320.
11. Rockafellar R. T. A dual approach to solving nonlinear programming problems by unconstrained optimization // *Mathematical Programming*. 1973. V. 5(1). P. 354–373.
12. Bertsekas D. P. *Constrained optimization and Lagrange Multiplier methods*. Computer Science and Applied Mathematics, Boston: Academic Press. 1982.
13. Wiener N. *Extrapolation, Interpolation, and Smoothing of Stationary Time Series*. The MIT Press. 1949.
14. Goodfellow I., Bengio Y., Courville A. *Deep Learning*. MIT Press, 2016.
15. Loshchilov I., Hutter F. Fixing weight decay regularization in adam // *arXiv:1711.05101*. 2017.
16. Huber P. J. Robust Estimation of a Location Parameter // *Ann. Math. Statist.* 1964. V. 35(1). P. 73–101.



**Дель Ирина Васильевна** — аспирант механико-математического факультета Национального Исследовательского Томского государственного университета, младший научный сотрудник лаборатории прогнозирования состояния

атмосферы Института оптики атмосферы СО РАН. Область научных интересов: машинное обучение, искусственные нейронные сети. E-mail: irina.del@mail.tsu.ru. Тел.: +7 (382) 252-95-53. Адрес: 634050, Томск, проспект Ленина, 36, ТГУ, ММФ.

**Del Irina Vasilievna** — postgraduate student of the Faculty of Mechanics and Mathematics, National Research Tomsk State University, junior researcher at the Laboratory of Atmospheric Prediction, Institute of Atmospheric Optics SB RAS. Research interests: machine learning, artificial neural networks. E-mail: irina.del@mail.tsu.ru. Tel: +7(382)-252-95-53. Address: 36, Lenin Avenue, Tomsk, 634050, TSU, MMF.

**Старченко Александр Васильевич** — доктор физ.-мат. наук, заведующий кафедрой

вычислительной математики и компьютерного моделирования Национального Исследовательского Томского государственного университета, главный научный сотрудник лаборатории прогнозирования состояния атмосферы Института оптики атмосферы СО РАН. Область научных интересов: численные методы, математическое моделирование, искусственные нейронные сети. E-mail: starch@math.tsu.ru. Тел.: +7 (382) 252-95-53. Адрес: 634050, Томск, проспект Ленина, 36, ТГУ, ММФ.



**Starchenko Alexander Vasilievich** — Doctor of Physical-Mathematical Sciences, Head of the Department of Computational Mathematics and Computer Modeling, National Research Tomsk State

University, Chief Scientific Associate of the Laboratory of Atmospheric Prediction, Institute of Atmospheric Optics SB RAS. Research interests: numerical methods, mathematical modeling, artificial neural networks. E-mail: starch@math.tsu.ru. Tel: +7(382)-252-95-53. Address: 36, Lenin Avenue, Tomsk, 634050, TSU, MMF.

*Дата поступления — 01.02.2025*