

МОДЕЛЬ ДЛЯ ПРОГНОЗИРОВАНИЯ ПОВЕРХНОСТНОЙ КОНЦЕНТРАЦИИ МЕТАНА В АРКТИЧЕСКОМ РЕГИОНЕ, ОСНОВАННАЯ НА ИСКУССТВЕННОЙ НЕЙРОННОЙ СЕТИ С ДЛИННОЙ ЦЕПЬЮ ЭЛЕМЕНТОВ КРАТКОСРОЧНОЙ ПАМЯТИ И ВЕЙВЛЕТ-ПРЕОБРАЗОВАНИЕМ ИСХОДНЫХ ДАННЫХ

А. Г. Бувечич, А. П. Сергеев, А. В. Шичкин, Е. М. Баглаева,
И. Е. Субботина, А. С. Буторова

Институт промышленной экологии Уральского отделения РАН (Екатеринбург, Российская Федерация)

Статья поступила в редакцию 12 апреля 2023 г.

Для цитирования

Бувечич А. Г., Сергеев А. П., Шичкин А. В. и др. Модель для прогнозирования поверхностной концентрации метана в арктическом регионе, основанная на искусственной нейронной сети с длинной цепью элементов краткосрочной памяти и вейвлет-преобразованием исходных данных // Арктика: экология и экономика. — 2023. — Т. 13, № 3. — С. 428—436. — DOI: 10.25283/2223-4594-2023-3-428-436.

Изучение динамики содержания парниковых газов в арктических районах планеты приобретает все большее значение. Такие исследования особенно актуальны в свете наблюдаемого в этом регионе изменения климата. В настоящей работе предлагается гибридная модель, которая сочетает вейвлет-преобразование исходных данных и искусственную нейронную сеть с длинной цепью элементов краткосрочной памяти (LSTM) для прогнозирования изменения приземной концентрации метана в арктических широтах. Временной ряд концентрации метана был разложен с помощью дискретного вейвлет-преобразования на четыре составляющих — одну аппроксимирующую и три детализирующих. Эти компоненты использовались для обучения сети LSTM. Прогноз рассчитывался как сумма прогнозов по каждому из компонентов. Всего были построены три прогнозные модели. В первой сеть LSTM обучалась в режиме нелинейной авторегрессии. Вторая представляла собой сочетание дискретного вейвлет-преобразования с нейронной сетью LSTM. Также для сравнения использовалась дополнительная модель на основе нелинейной авторегрессионной нейронной сети. Работа основана на данных экологического мониторинга парниковых газов на острове Белый Ямало-Ненецкого автономного округа. Исходные данные для построения модели были получены в июле-августе 2017 г. Точность прогноза оценивалась с помощью нескольких индикаторов. Гибридная модель на основе LSTM показала лучшую точность.

Ключевые слова: искусственные нейронные сети LSTM, временные ряды, вейвлет-преобразование, парниковые газы, метан, атмосфера.

Введение

В современных исследованиях все большую актуальность приобретают работы, связанные с прогнозированием динамики сложных природных процессов. Одной из наиболее успешно развивающихся областей является прогнозирование временных рядов различной природы. С развитием методов глубокого

обучения для прогнозирования временных рядов активно используются модели, в основе которых лежат различные варианты рекуррентных нейронных сетей (RNN). Такие сети показали высокую эффективность в экологических исследованиях, в частности, связанных с прогнозированием качества воздуха. Наиболее современной моделью RNN является искусственная нейронная сеть LSTM. Результаты применения LSTM показывают, что такая сеть позволяет успешно прогнозировать динамику временных рядов [1—10].

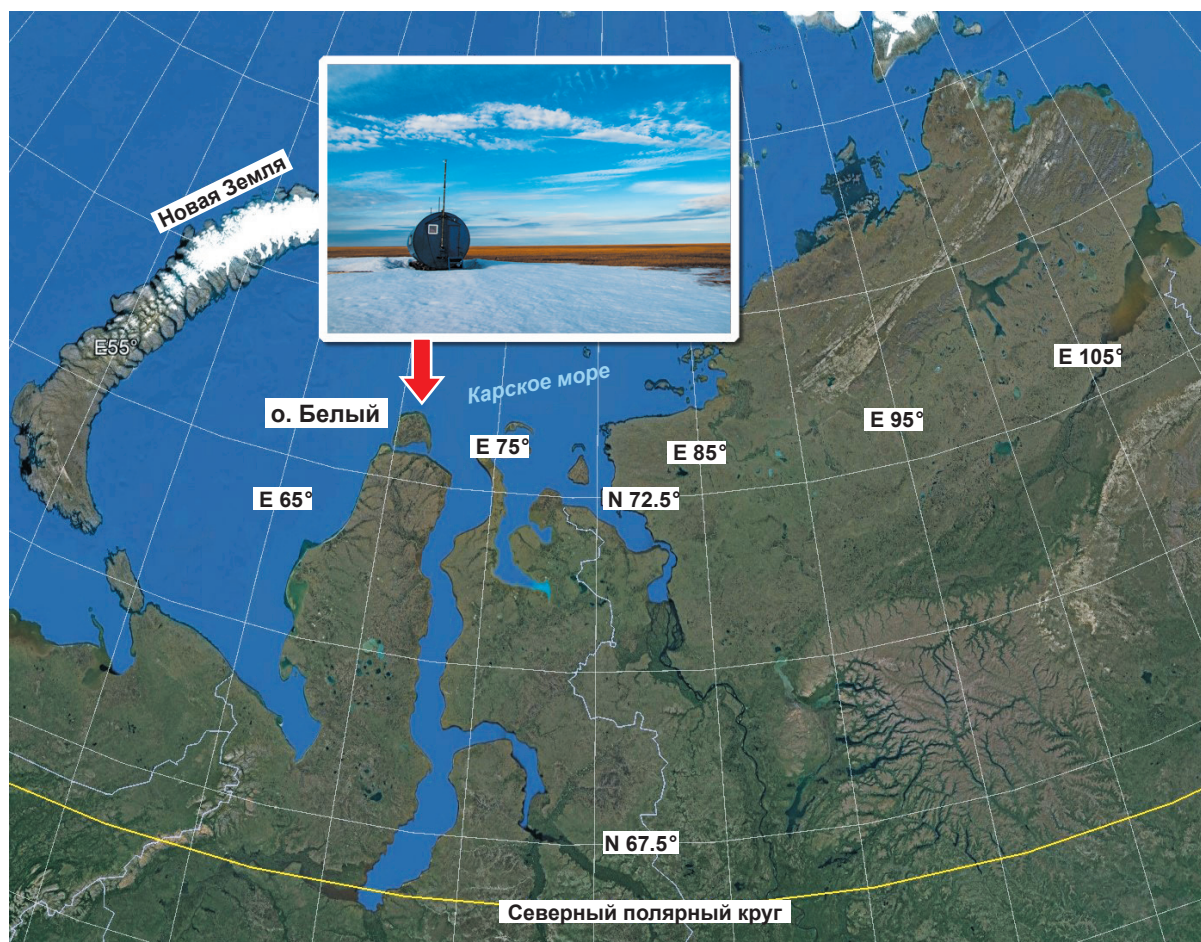


Рис. 1. Карта места измерения (Google Earth)
Fig. 1. Measurement site map (Google Earth)

Кроме того, исследователи предлагают различные варианты гибридных моделей на основе сетей LSTM, которые также успешно применяются для прогнозирования временных рядов [11—14]. Результаты применения LSTM в различных областях доказывают, что такая сеть может выявлять тенденции изменения данных и характеризовать зависимости в данных временной последовательности.

Для улучшения точности прогнозирования мы предлагаем гибридную модель, использующую вейвлет-преобразование данных для обучения нейронной сети LSTM. Вейвлет-преобразование используется при анализе временных рядов естественного происхождения [15—26]. Преимущество такого подхода состоит в том, что вейвлет-преобразование способно отображать исходный временной ряд на плоскости непрерывно меняющихся частотных и временных аргументов. Вейвлет-преобразование может выявлять различия характеристик временного ряда на разных масштабах, анализировать свойства временного ряда в разных точках на всем изучаемом интервале. Исследователи обычно используют ортогональные или биортогональные вейвлеты, для которых набор вейвлетов образует

ортогональный или биортогональный базис [27; 28]. Оптимальный выбор материнского вейвлета, по которому выполняется частотно-временная декомпозиция, является одной из основных задач анализа временных рядов. Каждый вейвлет имеет характерные особенности как во времени, так и в частотном пространстве. Используя разные вейвлеты, можно выявить различные особенности одного и того же исследуемого сигнала. Для анализа временных рядов естественного происхождения чаще всего используются вейвлеты Добеши (DWT) [15—26].

Цель работы — краткосрочный прогноз динамики приземной концентрации метана искусственными нейронными сетями, обученными на аппроксимирующих и детализирующих компонентах обучающих временных рядов метана, полученных методом дискретного вейвлет-преобразования. В предыдущих работах мы показали, что использование моделей на основе искусственной нейронной сети NARX и вейвлет-преобразование исходных данных [29; 30] позволяют дать точный краткосрочный прогноз изменения концентрации метана. В данном исследовании сделана попытка повысить точность прогноза за счет гибридной модели, сочетающей вейвлет-

Таблица 1. Показатели для оценки точности моделей
Table 1. Indicators for evaluating the accuracy of models

Показатель	Аббревиатура и формула
Средняя абсолютная ошибка	$MAE = \frac{\sum_{i=1}^n P(t_i) - O(t_i) }{n}$
Среднеквадратическая ошибка	$RMSE = \sqrt{\frac{\sum_{i=1}^n ((P(t_i) - O(t_i))^2}{n}}$
Среднеквадратическая относительная ошибка	$RMSRE = \sqrt{\frac{1}{n} \sum_{i=1}^n \left(\frac{P(t_i) - O(t_i)}{O(t_i)} \right)^2}$
Индекс согласия Уиллмотта	$IA = 1 - \frac{\sum_{i=1}^n P(t_i) - O(t_i) }{\sum_{i=1}^n (P(t_i) - \bar{O} + O(t_i) - \bar{O})}$

Примечание. $O(t_i)$ и $P(t_i)$ представляют собой значения исходного временного ряда и результата прогноза соответственно; \bar{O} — среднее значения исходного временного ряда и результата прогноза соответственно; n — количество моментов времени в тестовом временном ряду; t_i — момент времени.

преобразование данных и эффективную искусственную нейронную сеть LSTM.

Материалы и методы


Данные для исследования получены в июле 2017 г. на острове Белый Ямало-Ненецкого автономного округа. Остров Белый площадью около 1900 км² расположен в Карском море на расстоянии около 10 км от полуострова Ямал (рис. 1). Климат неустойчивый с быстрой сменой направления ветра и температуры. По международной климатической классификации остров Белый расположен в зоне полярных тундр. На нем нет промышленных предприятий и постоянного населения, кроме сотрудников действующей полярной метеостанции.

Измерения концентрации основных парниковых газов выполнялись на анализаторе Cavity Ring-Down Spectroscopy (CRDS) (G1401, PICARRO Inc). Исходные данные представляют собой пятисекундный временной ряд. Пятисекундные временные ряды усреднялись за каждый час. В результате получены 264 временные точки концентрации метана. Первые 216 временных точек использовались для обучения, а следующие 48 использовались для тестирования и в процессе обучения не участвовали. Тестовый временной ряд использовался только один раз для оценки ошибок прогноза (MAE, RMSE, RMSRE), показателей точности прогноза (IA) (табл. 1).

Для использования дискретного вейвлет-преобразования предварительно была проведена оценка оптимальной степени вейвлет-разложения. При более высокой степени суммарный прогноз улуч-

шается за счет уменьшения изменчивости сигнала. Однако при слишком большом количестве уровней вейвлет-разложения накапливается суммарная ошибка прогноза, в результате чего общий прогноз ухудшается. Для определения оптимальной степени разложения использовалось отношение стандартных отклонений исходного ряда и аппроксимирующего уровня разложения. В нашем случае отношение стандартных отклонений уменьшилось на 0,0775 для трех уровней разложения (для четырех оно составило 0,4082). В данном случае использовался симметричный вейвлет sym14.

LSTM представляет собой разновидность рекуррентных нейронных сетей (RNN) [31]. RNN — это нейронные сети, основанные на концепции временных слоев, что дает возможность использовать данные временных рядов в качестве входных и выходных данных. Однако у обычных RNN есть недостатки, например исчезающие и взрывающиеся градиенты [32]. Первоначально разработанная для учета долгосрочных зависимостей на этапе обучения LSTM может преодолеть недостатки RNN [33]. Основное предназначение сети — решение задач по классификации и прогнозированию временных рядов. Каждый модуль LSTM состоит из трех вентилях (вентиля ввода, вентиля вывода и вентиля забывания) и ячейки памяти. Ячейка памяти запоминает значения временного ряда через произвольные промежуток времени, а состояние всех трех вентилях контролирует состояние ячейки памяти. Вентиль забывания контролирует, какая информация будет удалена, а какая останется. Входной вентиль нужен



$$i_t = (W_{xi}x_t + W_{hi}h_{t-1} + W_{ci} \odot c_{t-1} + b_i)$$

$$f_t = (W_{xf}x_t + W_{hf}h_{t-1} + W_{cf} \odot c_{t-1} + b_f)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot \tanh(W_{xc}x_t + W_{hc}h_{t-1} + b_c)$$

$$o_t = (W_{xo}x_t + W_{ho}h_{t-1} + W_{co} \odot c_t + b_o)$$

$$h_t = o_t \odot \tanh(c_t)$$

Рис. 2. Схема сети LSTM. $W_{xi}, W_{hi}, W_{ci}, W_{xf}, W_{hf}, W_{cf}, W_{xo}, W_{ho}, W_{co}, W_{xc}$ – весовые параметры; b_i, b_f, b_c, b_o – параметры смещения; \tanh – функция активации нейронов (гиперболический тангенс); \odot – функция Адамара (поэлементного умножения матриц). Разработана автором

Fig. 2. LSTM network diagram. $W_{xi}, W_{hi}, W_{ci}, W_{xf}, W_{hf}, W_{cf}, W_{xo}, W_{ho}, W_{co}, W_{xc}$ – weight parameters; b_i, b_f, b_c, b_o – offset parameters; \tanh – функция активации нейронов (гиперболический тангенс) neuron activation function (hyperbolic tangent); \odot – Hadamard function (element-wise matrix multiplication). Developed by the author

для контроля поступающей на вход информации, а выходной вентиль управляет текущей информацией, которая поступает на выход нейронной сети (рис. 2).

Первые два метода прогноза представляют собой нейронную сеть LSTM. В первом сеть обучается в режиме нелинейной авторегрессии для предсказания динамики концентрации метана. Второй представляет собой сочетание дискретного вейвлет-преобразования с нейронной сетью LSTM. Исходный ряд раскладывается на аппроксимирующий и несколько детализирующих уровней разложения. Каждый из них разбивается на тренировочный и тестовый наборы, и прогнозируются значения для тестовой части. Все полученные прогнозы для всех уровней вейвлет-преобразования суммируются в один общий прогноз.

Для сравнения использовалась дополнительная модель NAR. Сеть может быть обучена для прогнозирования временных рядов на основе предыдущих значений и дополнительного параметра — временной задержки обратной связи. Сеть обучается в открытом цикле, используя реальные значения временного ряда. Обучение проводится до получения прогнозируемого значения, максимально близкого к исходному значению. По окончании обучения нейронная сеть преобразуется в замкнутый цикл, чтобы иметь возможность использовать прогнозируемые значения для подачи новых значений на вход обученной сети с целью предсказания на несколько шагов вперед.

Подробная схема всей методики численного эксперимента представлена на рис. 3.

В работе использовались следующие показатели для сравнения моделей и оценки точности прогноза (см. табл. 1): средняя абсолютная ошибка MAE, среднеквадратическая ошибка RMSE, среднеквадратическая относительная ошибка RMSRE, индекс согласия Уиллмотта IA [34; 35]. Индекс IA является стандартизированным показателем степени ошибки

предсказания модели и варьируется от 0 до 1, где значение 1 указывает на полное совпадение, а 0 указывает на полное отсутствие согласия.

Результаты и обсуждение

Описательная статистика для измеренной концентрации метана представлена в табл. 2.

В табл. 3 приведены результаты сравнения результатов моделей. Лучшие значения показателей выделены жирным шрифтом.

Предлагаемая гибридная модель LSTM sym14 имеет более низкие значения RMSE, RMSRE, MAE и более высокие индексы согласия Уиллмотта. Следует отметить, что обе модели на основе искусственной нейронной сети LSTM в целом демонстрируют лучшие показатели производительности, чем модель на основе искусственной нейронной сети NAR. Применение вейвлет-преобразования улучшило прогноз. Ошибки MAE, RMSE и RMSRE уменьшились на 25%, 10% и 40% соответственно. По показателю IA гибридная модель LSTM sym14 улучшилась на 7% относительно LSTM и на 46% относительно NAR.

На рис. 4 показан 48-часовой прогноз концентраций метана с помощью моделей искусственной нейронной сети LSTM и NAR, а также гибридного LSTM sym14.

Прогноз модели на основе искусственной нейронной сети NAR согласуется с измеренными данными по концентрациям метана в атмосферном воздухе хуже всех представленных. Прогноз гибридной модели LSTM sym14 наиболее точно отражает изменение концентрации CH_4 за 48 ч.

Заключение

В статье предлагается гибридный метод прогнозирования динамики временных рядов содержания метана. Модели на основе искусственных нейронных сетей LSTM и NAR сравниваются с гибридной моделью, сочетающей вейвлетную декомпозицию

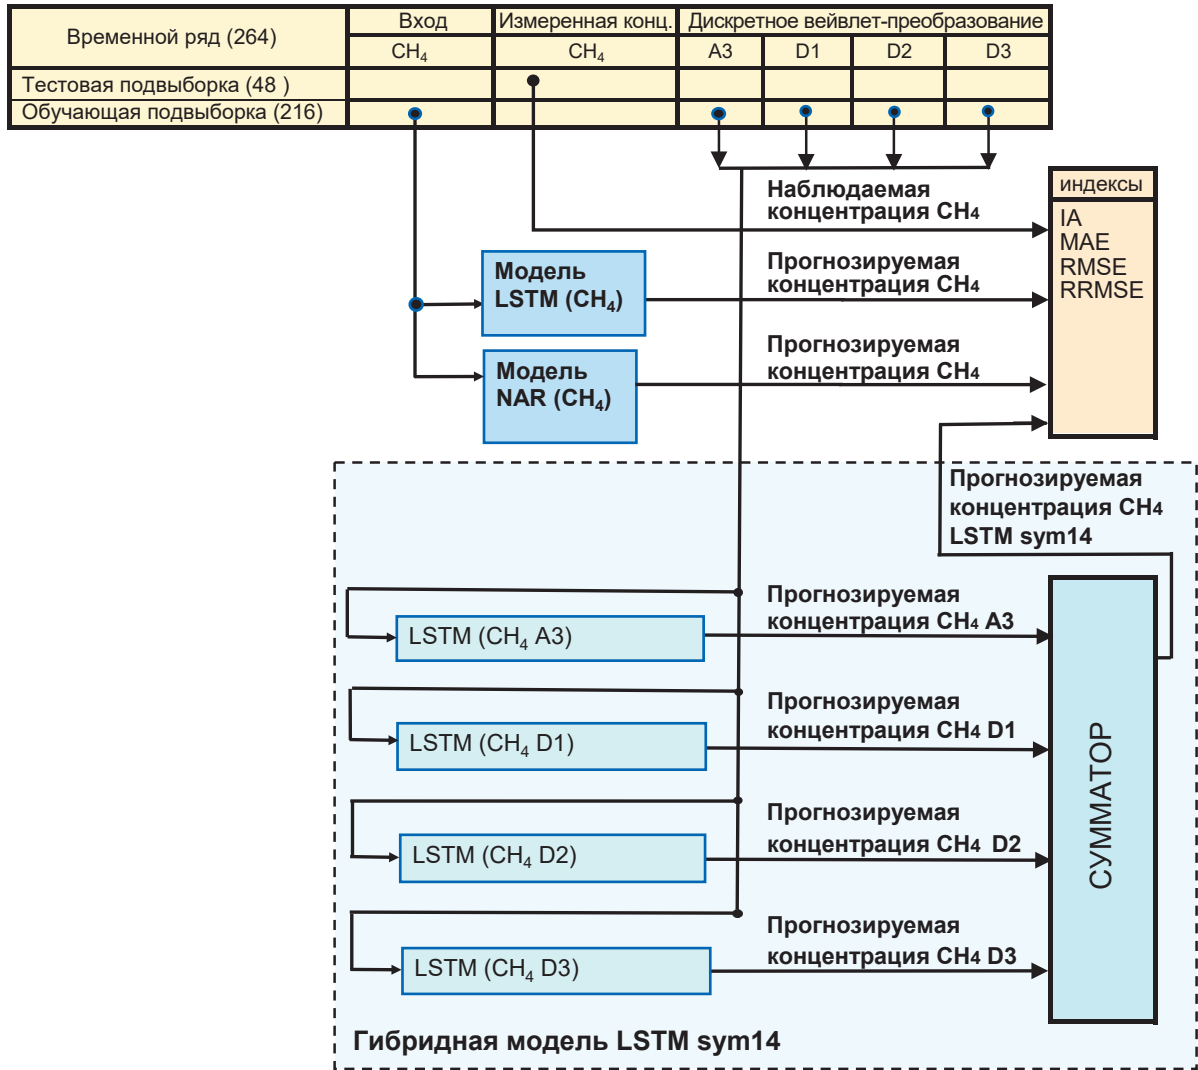


Рис. 3. Схема методики численного эксперимента. Разработана автором
Fig. 3. Scheme of the numerical experiment technique. Developed by the author

Таблица 2. Описательная статистика для измеренной концентрации метана CH₄ (мольная доля), ppm
Table 2. Descriptive statistics for the measured methane CH₄ concentration (the mole fraction), ppm

Минимальное значение	Максимальное значение	Среднее значение	Медиана	Стандартное отклонение	Коэффициент асимметрии	Экссесс
1,93	2,10	1,99	1,98	0,4	0,79	3,44

и последующее обучение на результатах декомпозиции (один аппроксимирующий и три детализирующих компонента) нейронных сетей LSTM. Таким образом, гибридную модель можно представить как обучение нейронных сетей на предварительно преобразованных данных. В целом анализ показывает, что точность прогнозирования повышается при обучении нейронных сетей на заранее подготовленных данных, полученных в результате дискретной вейвлет-декомпозиции. Использование этого метода по-

Таблица 3. Результаты прогноза моделей
Table 3. Model prediction results

Модель	IA	MAE	RMSRE	RMSE
LSTM sym14	0,92	0,015	0,009	0,018
LSTM	0,86	0,02	0,01	0,03
NAR	0,63	0,02	0,01	0,03




Рис. 4. Прогноз динамики концентрации метана. Разработан автором
Fig. 4. Forecast of methane concentration dynamics. Developed by the author

звоило разделить задачу прогнозирования на несколько подзадач, что дало возможность повысить точность прогнозирования. Прирост точности после применения предложенного подхода составил от 7% до 40% в зависимости от индикатора. Модели (гибридные и негибридные) на основе искусственной нейронной сети LSTM демонстрируют лучшие показатели производительности, чем модели на основе искусственной нейронной сети NAR.

В настоящее время ведется дальнейшая обработка данных о приземных концентрациях основных парниковых газов за более длительный период (сезоны, года), полученных в ходе мониторинга на острове Белый. Это позволит описать экосистемную динамику метана и других парниковых газов в атмосфере арктического острова Белый, что очень важно для правильной интерпретации полученных данных и более глубокого понимания происходящих процессов [16; 17].

Благодарность. Для измерения концентрации парниковых газов на острове Белый была использована аппаратура Центра коллективного пользования арктических экологических исследований Института промышленной экологии Уральского отделения РАН. Авторы признательны Ю. И. Маркелову за помощь в организации и проведении мониторинга, результаты которого легли в основу настоящей статьи. Также авторы выражают благодарность рецензенту за конструктивные комментарии.

Литература/References

1. Tao Q., Liu F., Li Y., Sidorov D. Air Pollution Forecasting Using a Deep Learning Model Based on 1D Convnets and Bidirectional GRU. *IEEE Access*, 2019, vol. 7, pp. 76690—76698. DOI: 10.1109/ACCESS.2019.2921578.
2. Zhao J., Deng F., Cai Y., Chen J. Long short-term memory — Fully connected (LSTM-FC) neural network for PM2.5 concentration prediction. *Chemosphere*, 2019, vol. 220, pp. 486—492.

3. Xu S., Niu R. Displacement prediction of Baijiabao landslide based on empirical mode decomposition and long short-term memory neural network in Three Gorges area, China. *Computers & Geosciences*, 2019, vol. 111, pp. 87—96. Available at: <https://doi.org/10.1016/j.cageo.2017.10.013>.
4. Tong W., Li L., Zhou X., Hamilton A., Zhang K. Deep learning 578 PM2.5 concentrations with bidirectional LSTM RNN. *Air Quality, Atmosphere & Health*, 2019, vol. 12 (4), pp. 411—423. Available at: <https://doi.org/10.1007/s11869-018-0647-4>.
5. Jung D.-H., Kim H. S., Jhin C., Kim H.-J., Park S. H. Time-series analysis of deep neural network models for prediction of climatic conditions inside a greenhouse. *Computers and Electronics in Agriculture*, 2020, vol. 173, p. 105402. Available at: <https://doi.org/10.1016/j.compag.2020.105402>.
6. Hamrani A., Akbarzadeh A., Madramootoo C. A. Machine learning for predicting greenhouse gas emissions from agricultural soils. *Science of The Total Environment*, 2020, vol. 741, p. 140338. Available at: <https://doi.org/10.1016/j.scitotenv.2020.140338>.
7. Li W., Kiaghadi A., Dawson C. High temporal resolution rainfall-runoff modeling using long-short-term-memory (LSTM) networks. *Neural Comput & Applic Environment*, 2021, vol. 33, pp. 1261—1278. Available at: <https://doi.org/10.1007/s00521-020-05010-6>.
8. Sherstinsky A. Fundamentals of Recurrent Neural Network (RNN) and Long Short-Term Memory (LSTM) network. *Physica D: Nonlinear Phenomena*, 2020, vol. 404, p. 132306. Available at: <https://doi.org/10.1016/j.physd.2019.132306>.
9. Memarzadeh G., Keynia F. A new short-term wind speed forecasting method based on fine-tuned LSTM neural network and optimal input sets. *Energy Conversion and Management Environment*, 2020, vol. 213, p. 112824. <https://doi.org/10.1016/j.enconman.2020.112824>.
10. Wang Y., Liu P., Xu C., Peng C., Wu J. A deep learning approach to real-time CO concentration prediction at signalized intersection. *Atmospheric Pollution Re-*

- search, 2020, vol. 11 (8), pp. 1370—1378. Available at: <https://doi.org/10.1016/j.apr.2020.05.007>.
11. Chang Y.-S., Chiao H.-T., Abimannan S., Huang Y.-P., Tsai Y.-T., Lin K.-M. An LSTM-based aggregated model for air pollution forecasting. *Atmospheric Pollution Research*, 2020, vol. 11 (8), pp. 1451—1463. Available at: <https://doi.org/10.1016/j.apr.2020.05.015>.
12. Zheng Y., Yi X., Li M., Li R., Shan Z., Chang E., Li T. Forecasting Fine-Grained Air Quality Based on Big Data. *KDD '15*, Australia: ACM, pp. 2267—2276. Available at: <https://doi.org/10.1145/2783258.2788573>.
13. Soh P., Chang J., Huang J. Adaptive Deep Learning-Based Air Quality Prediction Model Using the Most Relevant Spatial-Temporal Relations. *IEEE Access*, 2020, vol. 8, pp. 38186—38199. DOI: 10.1109/ACCESS.2018.2849820.
14. Ma J. Ding Y., Gan V. J. L., Lin C., Wan Z. Spatio-temporal Prediction of PM_{2.5} Concentrations at Different Time Granularities Using IDW-BLSTM. *IEEE Access*, 2020, vol. 7, p. 107907. DOI: 10.1109/ACCESS.2019.2932445.
15. Adamowski J., Chan H. F. A wavelet neural network conjunction model for groundwater level forecasting. *J. of Hydrology*, 2011, vol. 407 (1-4), pp. 28—40. Available at: <https://doi.org/10.1016/j.jhydrol.2011.06.013>.
16. Ebrahimi H., Rajaei T. Simulation of groundwater level variations using wavelet combined with neural network, linear regression and support vector machine. *Glob Planet Change*, 2017, vol. 148, pp. 181—191. Available at: <https://doi.org/10.1016/j.gloplacha.2016.11.014>.
17. Kalteh A. M. Monthly River flow forecasting using artificial neural network and support vector regression models coupled with wavelet transform. *Computers & Geosciences*, 2013, vol. 54, pp. 1—8. Available at: <https://doi.org/10.1016/j.cageo.2012.11.015>.
18. Graf R., Zhu S., Sivakumar B. Forecasting river water temperature time series using a wavelet-neural network hybrid modelling approach. *J. of Hydrology*, 2019, p. 124115. Available at: <https://doi.org/10.1016/j.jhydrol.2019.124115>.
19. Siwek K., Osowski S. Improving the accuracy of prediction of PM₁₀ pollution by the wavelet transformation and an ensemble of neural predictors. *Engineering Applications of Artificial Intelligence*, 2012, vol. 25 (6), pp. 1246—1258. Available at: <https://doi.org/10.1016/j.engappai.2011.10.013>.
20. Chen Y., Shi R., Shu S., Gao W. Ensemble and enhanced PM₁₀ concentration forecast model based on stepwise regression and wavelet analysis. *Atmospheric Environment*, 2013, vol. 74, pp. 346—359. Available at: <https://doi.org/10.1016/j.atmosenv.2013.04.002>.
21. Feng X., Li Q., Zhu Y., Hou J., Jin L., Wang J. Artificial neural networks forecasting of PM_{2.5} pollution using air mass trajectory based geographic model and wavelet transformation. *Atmospheric Environment*, 2016, vol. 107, pp. 118—128. Available at: <https://doi.org/10.1016/j.atmosenv.2015.02.030>.
22. Dunea D., Pohoata A., Iordache S. Using wavelet-feedforward neural networks to improve air pollution forecasting in urban environments. *Environmental Monitoring and Assessment*, 2015, vol. 187 (7), p. 477. Available at: <https://doi.org/10.1007/s10661-015-4697-x>.
23. Bai Y., Li Y., Wang X., Xie J., Li C. Air pollutants concentrations forecasting using back propagation neural network based on wavelet decomposition with meteorological conditions. *Atmospheric Pollution Research*, 2016, vol. 7 (3), pp. 557—566. Available at: <https://doi.org/10.1016/j.apr.2016.01.004>.
24. Cabaneros S. M., Calautit J. K., Hughes B. Spatial estimation of outdoor NO₂ levels in Central London using deep neural networks and a wavelet decomposition technique. *Ecological Modelling*, 2020, vol. 424, p. 109017. Available at: <https://doi.org/10.1016/j.ecolmodel.2020.109017>.
25. Osowski S., Garanty K. Forecasting of the daily meteorological pollution using wavelets and support vector machine. *Engineering Applications of Artificial Intelligence*, 2007, vol. 20 (6), pp. 745—755. Available at: <https://doi.org/10.1016/j.engappai.2006.10.008>.
26. Su X., An J., Zhang Y., Zhu P., Zhu B. Prediction of ozone hourly concentrations by support vector machine and kernel extreme learning machine using wavelet transformation and partial least squares methods. *Atmospheric Pollution Research Intelligence*, 2020, vol. 11 (6), pp. 51—60. Available at: <https://doi.org/10.1016/j.apr.2020.02.024>.
27. Mallat S. A theory for multiresolution signal decomposition: the wavelet representation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1989, vol. 11, pp. 674—693. Available at: <https://doi.org/10.1109/34.192463>.
28. Daubechies I. *Ten Lectures on Wavelets*. Philadelphia, PA, SIAM Press, 1988.
29. Buevich A., Sergeev A., Shichkin A., Baglaeva E. A two-step combined algorithm based on NARX neural network and the subsequent prediction of the residues improves prediction accuracy of the greenhouse gases concentrations. *Neural Computing and Applications*, 2021, vol. 33, pp. 1547—1557. Available at: <https://doi.org/10.1007/s00521-020-04995-4>.
30. Rakhmatova A., Sergeev A., Shichkin A., Buevich A., Baglaeva E. Three-day forecasting of greenhouse gas CH₄ in the atmosphere of the arctic Belyy island using discrete wavelet transform and artificial neural networks. *Neural Computing & Applications*, 2021, vol. 33, pp. 10311—10322.
31. Hochreiter S., Schmidhuber J. Long short-term memory. *Neural computation*, 1997, vol. 9 (8), pp. 735—1780.
32. Sainath T. N., Vinyals O., Senior A., Sak H. Convolutional, Long Short-Term Memory, fully connected Deep Neural Networks. *IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, South Brisbane, QLD, Australia. [S. I.], 2015, pp. 4580—4584. DOI: 10.1109/ICASSP.2015.7178838.

33. Fischer T., Krauss C. Deep learning with long short-term memory networks for financial market predictions. *European J. of Operational Research*, 2018, vol. 270 (2), pp. 654—669. Available at: <https://doi.org/10.1016/j.ejor.2017.11.054>.
34. Willmott C. J. On the Validation of Models. *Physical Geography*, 1981, vol. 2, pp. 184—194.
35. Willmott C. J., Robeson S. M., Matsuura K. A refined index of model performance. *Intern. J. of Climatol.*, 2012, vol. 32 (13), pp. 2088—2094. Available at: <https://doi.org/10.1002/joc.2419>.
-

Информация об авторах

Бувевич Александр Геннадьевич, научный сотрудник, Институт промышленной экологии Уральского отделения РАН (620990, Екатеринбург, ул. С. Ковалевской, д. 20), e-mail: bagalex3@gmail.com.

Сергеев Александр Петрович, кандидат физико-математических наук, ведущий научный сотрудник, Институт промышленной экологии Уральского отделения РАН (620990, Екатеринбург, ул. С. Ковалевской, д. 20), e-mail: aleksandrpsergeev@gmail.com.

Шичкин Андрей Васильевич, научный сотрудник, Институт промышленной экологии Уральского отделения РАН (620990, Екатеринбург, ул. С. Ковалевской, д. 20), e-mail: and@ecko.uran.ru.

Баглаева Елена Михайловна, кандидат физико-математических наук, старший научный сотрудник, Институт промышленной экологии Уральского отделения РАН (620990, Екатеринбург, ул. С. Ковалевской, д. 20), e-mail: sem@ecko.uran.ru.

Субботина Ирина Евгеньевна, кандидат физико-математических наук, научный сотрудник, Институт промышленной экологии Уральского отделения РАН (620990, Екатеринбург, ул. С. Ковалевской, д. 20), e-mail: iesub@mail.ru.

Буторова Анастасия Сергеевна, младший научный сотрудник, Институт промышленной экологии Уральского отделения РАН (620990, Екатеринбург, ул. С. Ковалевской, д. 20), e-mail: amoskalyova03@gmail.com.

A HYBRID MODEL BASED ON AN ARTIFICIAL NEURAL NETWORK WITH A LONG CHAIN OF SHORT-TERM MEMORY ELEMENTS AND DISCRETE WAVELET TRANSFORM FOR PREDICTING SURFACE METHANE CONTENT IN THE ARCTIC AREA

Buevich, A. G., Sergeev, A. P., Shichkin, A. V., Baglaeva, E. M., Subbotina, I. E., Butorova, A. S.

Institute of Industrial Ecology of the Ural Branch of RAS (Ekaterinburg, Russian Federation)

The article was received on April 12, 2023

For citing

Buevich A. G., Sergeev A. P., Shichkin A. V., Baglaeva E. M., Subbotina I. E., Butorova A. S. A hybrid model based on an artificial neural network with a long chain of short-term memory elements and a discrete wavelet transform for predicting surface methane content in the Arctic area. *Arctic: Ecology and Economy*, 2023, vol. 13, no. 3, pp. 428—436. DOI: 10.25283/2223-4594-2023-3-428-436.

Abstract

The study of the dynamics of greenhouse gases in the Arctic regions of the planet is becoming increasingly important. Such studies are especially relevant due to the climate change observed in this region. The paper propose a hybrid model that combines wavelet transformation of the original data and an artificial neural network with a long chain of short-term memory (LSTM) elements to predict changes in the surface methane concentration in the Arctic latitudes. The methane concentration time series via a discrete wavelet transform was decomposed into four components — one approximating and three detailing ones. These components were used to train the LSTM network. The forecast was calculated as the sum of forecasts for each of the components. Three predictive models were built. In the first, the LSTM network was trained in a non-linear autoregressive mode. The second one was a combination of discrete wavelet transform with LSTM neural network. An additional model based on a non-linear autoregressive neural network (NAR) was also used for comparison. The work is based on data from environmental monitoring of greenhouse gases on Bely Island, Yamalo-Nenets Autonomous Area of Russia. The initial data for building the proposed model were obtained within July-August 2017. The accuracy of the forecast was assessed using several indicators. The hybrid model based on LSTM showed the best accuracy.

Keywords. *LSTM artificial neural networks, time series, wavelet transform, greenhouse gases, methane, atmosphere.*

Acknowledgements. The equipment of the Common Use Center of Arctic Environmental Research of the Institute of Industrial Ecology of the Ural Branch of RAS was used to measure the concentration of greenhouse gases on Bely Island. The authors are grateful to Yu. I. Markelov for his help in organizing and conducting monitoring, the results of which formed the basis of this article. The authors also thank the reviewer for constructive comments.

Information about the authors

Buevich, Alexander Gennadievich, Researcher, Institute of Industrial Ecology, Ural Branch of the Russian Academy of Sciences (20, S. Kovalevskoy str., Ekaterinburg, 620990), e-mail: bagalex3@gmail.com.

Sergeev, Aleksandr Petrovich, PhD of Physical and Mathematical Sciences, Leading Researcher, Institute of Industrial Ecology, Ural Branch of the Russian Academy of Sciences (20, S. Kovalevskoy str., Ekaterinburg, 620990), e-mail: aleksandrpsergeev@gmail.com.

Shichkin, Andrey Vasilievich, Researcher, Institute of Industrial Ecology, Ural Branch of the Russian Academy of Sciences (20, S. Kovalevskoy str., Ekaterinburg, 620990), e-mail: and@ecko.uran.ru.

Baglaeva, Elena Mikhailovna, PhD of Physical and Mathematical Sciences, Senior Researcher, Institute of Industrial Ecology, Ural Branch of the Russian Academy of Sciences (20, S. Kovalevskoy str., Ekaterinburg, 620990), e-mail: sem@ecko.uran.ru.

Subbotina, Irina Evgenievna, PhD of Physical and Mathematical Sciences, Researcher, Institute of Industrial Ecology, Ural Branch of the Russian Academy of Sciences (20, S. Kovalevskoy str., Ekaterinburg, 620990), e-mail: iesub@mail.ru.

Butorova, Anastasia Sergeevna, Junior Researcher, Institute of Industrial Ecology, Ural Branch of the Russian Academy of Sciences (20, S. Kovalevskoy str., Ekaterinburg, 620990), e-mail: amoskalyova03@gmail.com.

© Buevich A. G., Sergeev A. P., Shichkin A. V., Baglaeva E. M., Subbotina I. E., Butorova A. S., 2023