

СРАВНИТЕЛЬНЫЙ АНАЛИЗ НЕЙРОСЕТЕВЫХ МОДЕЛЕЙ ДЛЯ ПРОГНОЗА ДИНАМИКИ КОНЦЕНТРАЦИЙ ПАРНИКОВЫХ ГАЗОВ В ПРИЗЕМНОМ СЛОЕ АТМОСФЕРНОГО ВОЗДУХА ОСТРОВА БЕЛЫЙ

В. С. Бобаков, А. Г. Буевич, А. С. Буторова, А. П. Сергеев

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

Статья поступила в редакцию 23 июля 2025 г.

Для цитирования

Бобаков В. С., Буевич А. Г., Буторова А. С., Сергеев А. П. Сравнительный анализ нейросетевых моделей для прогноза динамики концентраций парниковых газов в приземном слое атмосферного воздуха острова Белый // Арктика: экология и экономика. — 2026. — Т. 16, № 1. — С. 53—63. — DOI: 10.25283/2223-4594-2026-1-53-63.

В последние годы применение технологий на основе машинного обучения все более актуально для мониторинга выбросов парниковых газов в Арктике, где наблюдаются интенсивная деградация многолетнемерзлых пород и увеличение выбросов метана в атмосферу. В настоящей работе созданы и сравнены модели на основе рекуррентных и графовой нейронных сетей для прогнозирования динамики концентраций основных парниковых и угарного газов в приземном слое атмосферного воздуха арктического острова Белый (Россия, Ямало-Ненецкий автономный округ). Исходный набор данных представлял собой измерения приземной концентрации четырех газов за летние месяцы 2016–2017 гг.: углекислого газа, метана, угарного газа и водяного пара. Для прогнозирования при помощи графового метода использовалась модель Multivariate Time Series Graph Neural Network (MTGNN), прогнозирование при помощи рекуррентного метода производилось при помощи моделей Long Short-Term Memory (LSTM) и Long Short-Term Memory Network (LSTNet). Точность прогноза моделей оценивалась при помощи следующих метрик: средней абсолютной ошибки MAE, среднеквадратической ошибки RMSE, нормализованной среднеквадратической ошибки NRMSE, коэффициента корреляции Corr. В целом модель MTGNN продемонстрировала более низкие значения ошибок по сравнению с рекуррентными моделями. У MTGNN по сравнению с LSTM и LSTNet ошибки ниже на 25–55%. Более точная графовая модель потребовала значительно большего времени для обучения и имела существенно большее количество параметров для оптимизации.

Ключевые слова: временные ряды, парниковые газы, Арктика, прогноз, нейронные сети, графовые нейронные сети, LSTM.

Введение

Рекуррентные нейронные сети (RNN) и графовые нейронные сети (GNN) играют ключевую роль в современном машинном обучении, оба эти подхода используются для создания прогнозов с учетом различных сложных нелинейных взаимосвязей в данных. Так, RNN эффективны в обработках последовательных данных, так же как и графовые нейронные сети, которые могут представлять данные в виде различных графов.

Рекуррентные нейронные сети типа LSTM и GRU используются для моделирования различных временных зависимостей и долгосрочной памяти в последовательных данных [1–3]. Такие модели используются для прогнозирования урбанистических мобильных паттернов [4], что подтверждает их высокую эффективность в задачах анализа временных рядов.

Графовые нейронные сети также могут использоваться для прогнозирования. Они особенно полезны при решении задач, где важно учитывать пространственные зависимости, например для метеороло-

гических данных, данных о дорожном движении и т. п. [5—9]. Однако эффективность применения GNN зависит от выбранного подхода к построению графа в нейронной сети. Существует много способов построения графов — временных, статических, пространственно-временных. Так, временные графы представляют собой структуры, где ребра и узлы могут изменяться во времени. Такие графы особенно эффективны в задачах прогнозирования последовательностей или моделирования динамических систем [10]. Статические графы представляют собой неизменные структуры, где узлы и ребра фиксированы, что может быть полезно для решения задач, где связи между данными постоянны [11]. Пространственно-временные графы объединяют узлы и ребра так, чтобы моделировать зависимости объектов в пространстве и их изменения во времени. Они широко применяются для анализа транспортных сетей, предсказания погодных условий и медицинской диагностики [12].

Однако графовые нейронные сети требуют сложных вычислений, особенно при обработке данных с большим количеством узлов и ребер [13]. В таких задачах, как моделирование транспортных сетей или социальных графов, GNN могут стать неэффективными из-за необходимости повторного обучения на графах большой размерности. RNN, напротив, хорошо работают с последовательными данными, не требуя моделирования сложных графовых связей, что снижает нагрузку на вычислительные ресурсы.

Применение таких технологий актуально для мониторинга выбросов парниковых газов в Арктике, где наблюдаются интенсивная деградация многолетне-мерзлых пород и увеличение выбросов метана в атмосферу. Поэтому гибридные подходы, сочетающие LSTM с дискретным вейвлет-преобразованием, показали выдающиеся результаты. Например, для прогнозирования концентрации метана в арктическом регионе совместное использование LSTM и вейвлет-преобразования позволило значительно снизить ошибки прогноза и повысить точность на 70—79% [14]. Другие нейросетевые модели, такие как NARX, также показали высокую корреляцию между прогнозируемыми и наблюдаемыми концентрациями метана, что подтверждает их эффективность для задач краткосрочного прогнозирования [15; 16]. Последние исследования выявили, что в 2019—2021 гг. концентрация метана в Циркумарктическом мегарегионе и на полуострове Ямал была ниже глобального уровня. В 2020 г. повышение температуры на Ямале способствовало увеличению выбросов метана, тогда как аномальные холода 2021 г. препятствовали выходу газа из мерзлых слоев почвы [17; 18]. Эти данные подчеркивают, что для повышения точности прогнозов в гибридных моделях важно учитывать сезонные и температурные колебания [19—21]. Несмотря на преимущества в обработке последовательностей, RNN могут сталкиваться с трудностями при учете динамических изменений в Арктике, связанных с изменением климата. Например, резкие температурные

колебания могут создавать сложные, нестабильные последовательности, что затрудняет составление точных прогнозов.

Целью настоящего исследования является сравнение эффективности моделей на основе рекуррентных и графовой нейронных сетей для прогнозирования динамики концентраций основных парниковых и угарного газов в приземном слое атмосферного воздуха арктической территории.

Материалы и методы

Сбор исходных данных и их описание

Для проведения исследования использовались данные, полученные за летние месяцы 2016—2017 гг. на арктическом острове Белый, расположенном в Ямало-Ненецком автономном округе России. На острове нет постоянного населения. Его площадь составляет 1810 км². Там много термокарстовых озер, рек и болот. Поверхность равнинная, постепенно поднимающаяся к югу, где достигает максимальной высоты 12 м над уровнем моря. Северное и восточное побережья низкие, песчаные, на западном и южном берегах местами встречаются обрывы до 6 м высотой. Почва состоит из глины и песка с вечной мерзлотой на глубине от 50 до 60 см. Поверхность покрыта тундровой растительностью: травами, мхами и карликовыми ивами. Среднегодовая температура составляет -10,6°C. Исследования велись в северо-западной части острова в районе гидрометеорологической станции им. М. В. Попова.

Измерения проводились на высоте 7 м спектро-скопическим анализатором Cavity Ring-Down (CRDS) модели G1401 производства PICARRO Inc. (США). В качестве исходной информации использовались пятисекундные данные о содержании в атмосфере CO₂, CH₄, CO и H₂O. В результате почасового усреднения получены четыре реализации временных рядов, содержащих 2445 временных отсчетов. В исследуемом периоде после почасового усреднения данные не имели пропусков и аномалий.

Нормализация, сглаживание и разбиение исходных данных

Наблюдаемые значения четырех временных рядов были последовательно сглажены скользящим окном, а затем нормализованы:

$$z(i) = \frac{\sum_{j=i}^{j=m+i-1} \left(\frac{o(j) - \bar{o}}{s_o} \right)}{m}, \quad i = 1, \dots, n - m + 1,$$

$$\bar{o} = \frac{1}{n} \sum_{j=1}^{j=n} o(j), \quad s_o = \sqrt{\frac{\sum_{j=1}^{j=n} (o(j) - \bar{o})^2}{n - 1}},$$

где $z(i)$ — значение сглаженного и нормализованного временного ряда в момент времени i ; $o(j)$ — значение наблюдаемого временного ряда; \bar{o} — выборочное среднее временного ряда; s_o — выборочное

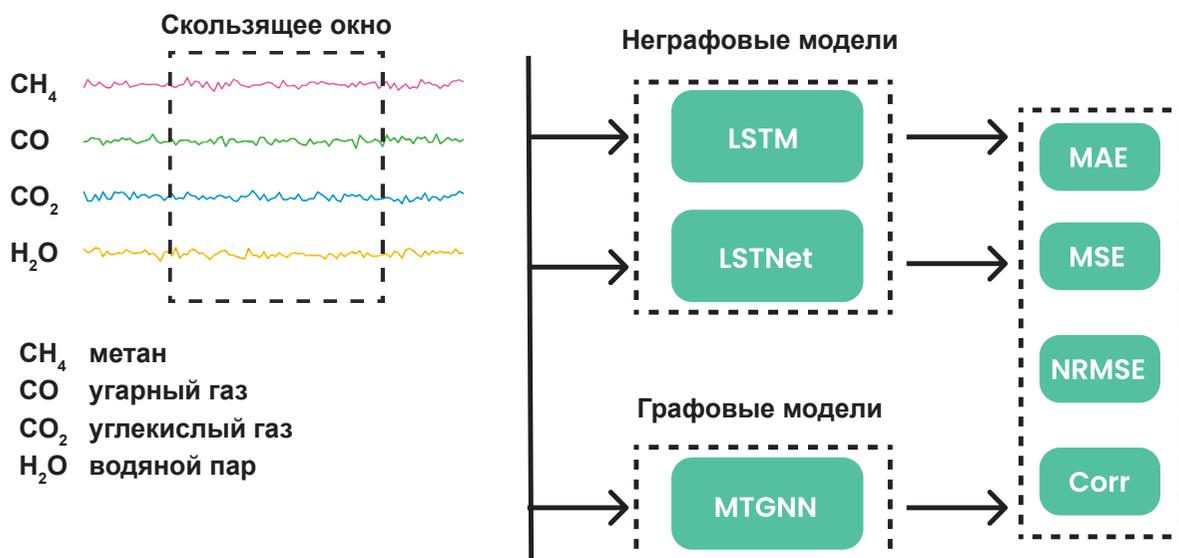


Рис. 1. Схема методики численного эксперимента. Составлена авторами
Fig. 1. Scheme of the numerical experiment methodology. Compiled by the authors

стандартное отклонение; $m = 10$ — размер скользящего окна; n — размер наблюдаемого временного ряда.

Сглаженные и нормализованные временные ряды были разбиты на тренировочные, тестовые и валидационные выборки в соотношении 70%/10%/20% соответственно.

Модели и входные данные

В качестве входных данных для обучения всех рассматриваемых моделей использовались значения четырех переменных (концентраций CH₄, H₂O, CO, CO₂) — сглаженных и нормализованных рядов в скользящем окне. Ширина окна подбиралась отдельно для каждой модели так, чтобы процесс обучения был оптимальным — максимально возможная производительность при разумных вычислительных затратах.

Схема применяемой методики приведена на рис. 1.

Для прогнозирования динамики концентраций газов были выбраны модели LSTM, LSTNet и MTGNN, так как каждая из них хорошо справляется с временными рядами:

- LSTM и LSTNet — рекуррентные модели, способные удерживать информацию о прошлых отсчетах и выявлять временные зависимости при относительно небольшом окне (48 отсчетов).
- MTGNN сочетает графовые и временные сверточные блоки, что позволяет захватывать долгосрочные зависимости во временном ряду (использовалось окно 96 отсчетов). Хотя графовая структура обычно применяется при нескольких датчиках, в данной работе она помогла модели лучше извлекать сложные временные паттерны.

Модель Long Short-Term Memory (LSTM)

LSTM — это тип рекуррентной нейронной сети, использующий ячейку памяти для хранения долго-

временной информации. Управление данными осуществляется через три шлюза: забывания (удаляет ненужное), входных данных (добавляет новое) и выходных данных (передает важное дальше). Благодаря такому механизму управления модель LSTM способна запоминать важные детали в длинных последовательностях данных, эффективно справляясь с проблемой исчезающего градиента, которая затрудняет обучение традиционных рекуррентных нейронных сетей.

Модель Long Short-Term Memory Network (LSTNet)

LSTNet — это гибридная модель, сочетающая несколько подходов для анализа временных рядов. Она использует сверточные нейронные сети (CNN) для выделения локальных зависимостей, LSTM для долгосрочных зависимостей и авторегрессию для краткосрочных. Важным элементом является модуль Skip-RNN, позволяющий передавать данные между удаленными слоями, минуя промежуточные. Это сохраняет информацию из предыдущих слоев и помогает учитывать периодические закономерности. Такая архитектура эффективно моделирует сложные временные ряды, обрабатывая как локальные, так и глобальные зависимости.

Модель Multivariate Time Series Graph Neural Network (MTGNN)

Модель MTGNN объединяет графовые нейронные сети GNN и временные сверточные сети TCN для анализа многомерных временных рядов. GNN используются для выявления зависимостей между различными переменными, моделируя их взаимодействия в виде графа. TCN, в свою очередь, специализируются на захвате временных закономерностей, анализируя изменения данных во времени. Такая интеграция позволяет MTGNN эффективно изучать как пространственные, так и временные

зависимости, что делает модель подходящей для сложных задач, таких как прогнозирование многомерных временных рядов.

Для построения графа в модели MTGNN используется комбинация обучаемой структуры графа и локальных подграфов, которая позволяет захватывать зависимости между узлами временного ряда даже при ограниченном количестве сенсоров. В частности:

- граф строится с помощью GCN-блоков (Graph Convolutional Networks), где `gcn_true = True` и `build_adj = True`, что означает, что модель одновременно использует как фиксированное, так и обучаемое смежностное представление узлов;
- подграфы (`subgraph_size = 3`) формируют локальные кластеры узлов, которые участвуют в свертках, что позволяет модели выявлять локальные паттерны во временном ряду;
- параметры `gcn_depth = 3` и `dilation_exponential = 2` обеспечивают захват долгосрочных зависимостей, расширяя рецептивное поле по временной оси;
- skip- и residual-связи (`skip_channels = 32`, `residual_channels = 16`) повышают устойчивость обучения и позволяют эффективно передавать информацию через несколько слоев графа.

Таким образом, граф в MTGNN строится не на основе физической сети сенсоров, а исходя из статистических и временных корреляций между отсчетами ряда, что особенно полезно при одном датчике и коротких временных окнах. Выбранный подход позволил модели лучше выявлять сложные временные закономерности и обеспечил ее высокую продуктивность, несмотря на малое количество входных узлов.

Оценка точности моделей

Для оценки точности построенных моделей использовались следующие метрики: средняя абсолютная ошибка MAE, среднеквадратическая ошибка RMSE, нормализованная среднеквадратическая ошибка NRMSE, коэффициент корреляции Corr.

$$MAE = \frac{1}{n} \sum_{i=1}^n |p_i - o_i|;$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (p_i - o_i)^2};$$

$$NRMSE = \frac{\sum_{i=1}^n (p_i - o_i)^2}{\sum_{i=1}^n o_i^2};$$

$$Corr = \frac{\sum_{i=1}^n (p_i - \bar{p})(o_i - \bar{o})}{\sqrt{\sum_{i=1}^n (p_i - \bar{p})^2 \sum_{i=1}^n (o_i - \bar{o})^2}},$$

где o_i — сглаженное и нормализованное наблюдаемое значение; p_i — прогнозируемое значение для

сглаженного и нормализованного ряда; \bar{o} — среднее наблюдаемое значение; \bar{p} — среднее прогнозируемое значение.

Также для визуализации производительности моделей использовалась диаграмма Тейлора для сглаженного и нормализованного ряда.

Результаты и обсуждение

Для прогнозирования динамики концентраций газов использовались две рекуррентные модели: LSTM (ширина окна — 48 отсчетов), LSTNet (ширина окна — 48 отсчетов) и графовая модель MTGNN (ширина окна — 96 отсчетов). Таким образом, первые 48 отсчетов в тестовом и валидационном фрагментах для моделей LSTM и LSTNet и первые 96 отсчетов в тестовом и валидационном фрагментах для модели MTGNN не предсказывались.

LSTM использует механизмы «забывания» через forget-gate, чтобы отбрасывать неважную информацию. Если окно слишком длинное, модель начинает «размывать» значимые зависимости, особенно если важные паттерны находятся ближе к концу окна.

MTGNN сочетает временные свертки и графовые операции, которые позволяют захватывать более протяженные во времени корреляции между параметрами. В отличие от LSTM MTGNN не зависит от рекуррентного состояния, поэтому оно лучше справляется с длинными окнами без потери информации о последних отсчетах.

Усредненное время обучения для MTGNN составило 1254 с, для LSTM — 77 с, для LSTNet — 66 с. Обучение проходило на четырехъядерном процессоре IntelCore i7 2,3 GHz.

Описательная статистика представлена в табл. 1.

В табл. 2 приведены результаты оценки эффективности моделей. Лучшие значения метрик выделены полужирным шрифтом.

Общий анализ табл. 2 показывает, что модель MTGNN стабильно превосходит LSTM и LSTNet по всем ключевым метрикам прогнозирования (MAE, RMSE, NRMSE, Corr) для всех четырех газов CO₂, CH₄, CO и H₂O. В среднем по сравнению с LSTM MTGNN снижает MAE на 25—45%, а по сравнению с LSTNet — на 35—55%. Аналогичное снижение наблюдается и по RMSE. Например, для CH₄ MAE у MTGNN составляет всего 0,026, в то время как у LSTM — 0,048, что означает снижение ошибки на 45,8%. По H₂O MTGNN показывает MAE 0,030 против 0,050 у LSTM — снижение на 40%.

Стоит отметить, что, несмотря на прирост точности в показателях, графовая модель требовала значительно больше времени для обучения и имела существенно большее количество параметров для оптимизации. Это делает ее ресурсоемкой по сравнению с рекуррентными моделями LSTM и LSTNet, которые, в свою очередь, демонстрируют высокую производительность при меньших вычислительных затратах. Таким образом, выбор модели зависит от доступных ресурсов и требований к точности.

Таблица 1. Описательная статистика исходных данных

Table 1. Descriptive statistics of the original data

| Газ | Статистики | | | | | |
|------------------|--------------|-----------------------------|--------------|---------------|--------------|-----------|
| | Среднее, ppm | Стандартное отклонение, ppm | Минимум, ppm | Максимум, ppm | Медиана, ppm | Мода, ppm |
| CH ₄ | 1,95 | 0,06 | 1,89 | 2,34 | 1,92 | 1,89 |
| H ₂ O | 0,92 | 0,24 | 0,41 | 1,78 | 0,88 | 0,41 |
| CO | 0,09 | 0,02 | 0,07 | 0,29 | 0,09 | 0,07 |
| CO ₂ | 393 | 2,95 | 382 | 407 | 393 | 382 |

Таблица 2. Оценка эффективности моделей

Table 2. Evaluation of the effectiveness of models

| Газ | Модель | MAE | RMSE | NRMSE | Коэффициент корреляции |
|------------------|--------|-------|-------|-------|------------------------|
| CO ₂ | MTGNN | 0,033 | 0,048 | 0,111 | 0,994 |
| | LSTM | 0,036 | 0,054 | 0,125 | 0,992 |
| | LSTNet | 0,043 | 0,063 | 0,146 | 0,989 |
| CH ₄ | MTGNN | 0,026 | 0,041 | 0,061 | 0,998 |
| | LSTM | 0,048 | 0,072 | 0,106 | 0,995 |
| | LSTNet | 0,045 | 0,070 | 0,104 | 0,996 |
| CO | MTGNN | 0,021 | 0,027 | 0,072 | 0,998 |
| | LSTM | 0,038 | 0,057 | 0,153 | 0,990 |
| | LSTNet | 0,044 | 0,063 | 0,170 | 0,986 |
| H ₂ O | MTGNN | 0,030 | 0,047 | 0,089 | 0,997 |
| | LSTM | 0,050 | 0,069 | 0,131 | 0,993 |
| | LSTNet | 0,062 | 0,078 | 0,150 | 0,992 |

Модель MTGNN показала наивысшие показатели точности среди рассмотренных моделей благодаря способности выявлять структурные и временные зависимости между признаками. В частности:

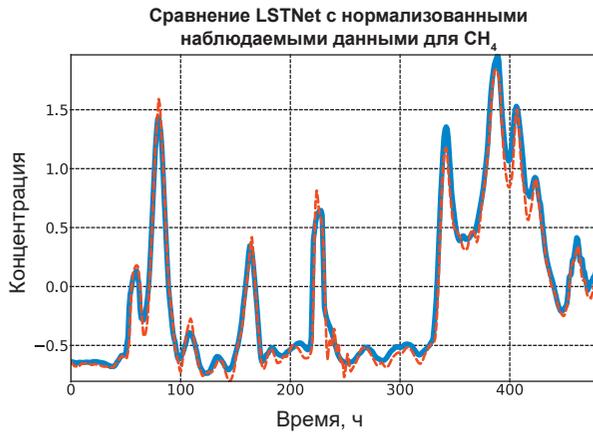
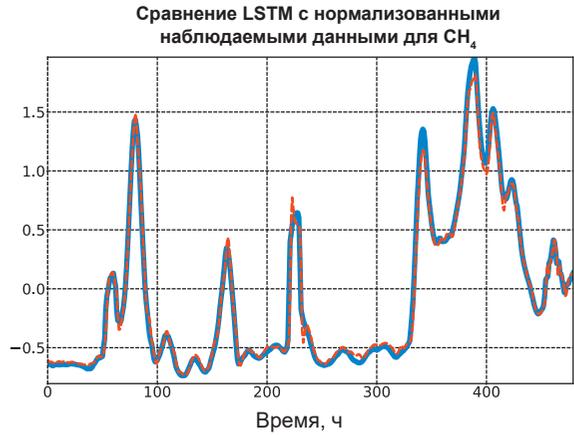
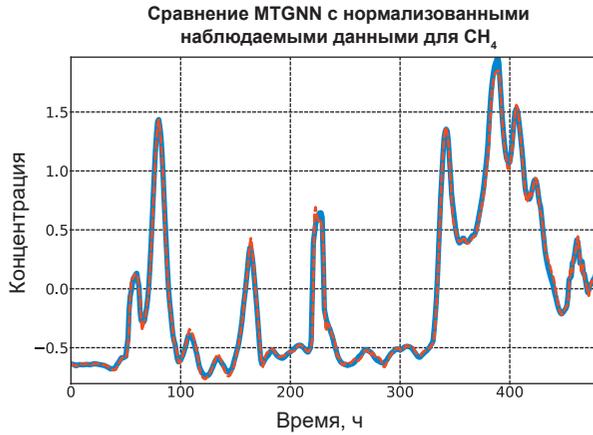
- локальные паттерны: подграфы (`subgraph_size = 3`) позволяют модели фиксировать локальные закономерности во временных рядах, например, краткосрочные колебания концентраций газа;
- долгосрочные зависимости: параметры `gcn_depth = 3` и `dilation_exponential = 2` расширяют рецептивное поле по времени, что помогает учитывать тенденции на более длинных интервалах;
- обучаемая структура графа: `build_adj = True` и `gcn_true = True` дают возможность адаптировать граф к данным и выявлять скрытые корреляции между четырьмя признаками.

Однако абсолютные различия в метриках точности между MTGNN и рекуррентными моделями невелики, что указывает на то, что для небольшого

числа признаков (четырёх) применение GNN может быть избыточным. Преимущества графовой модели становятся особенно заметны при большем числе узлов или более сложной пространственно-временной структуре данных.

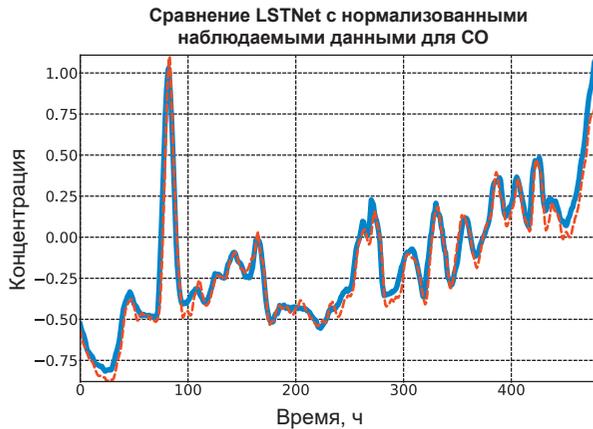
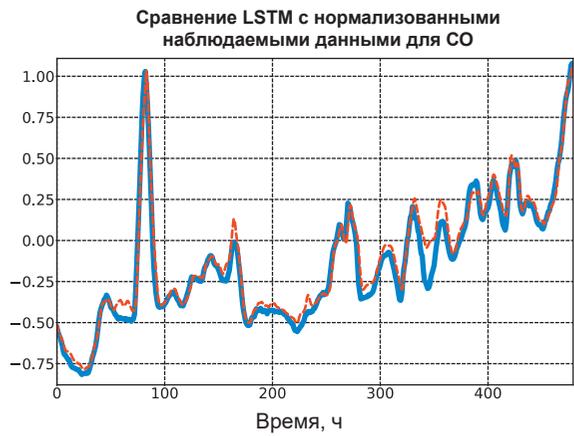
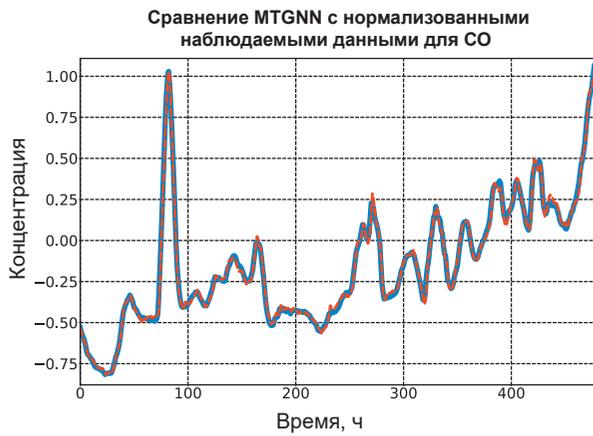
На рис. 2—5 показан прогноз временных рядов с использованием моделей LSTM, LSTNet и MTGNN. Все модели продемонстрировали хорошие результаты, успешно справившись с задачей прогнозирования.

Все анализируемые подходы адекватно воспроизвели общую тенденцию в динамике временных рядов, однако графовая сеть точнее описывала наблюдаемые закономерности и не нуждалась в дополнительных линейных корректировках. Кроме того, рекуррентные модели хуже справлялись с резкими пиками и переходами в данных, что особенно заметно при прогнозировании многомерных временных рядов (см. рис. 2—5).



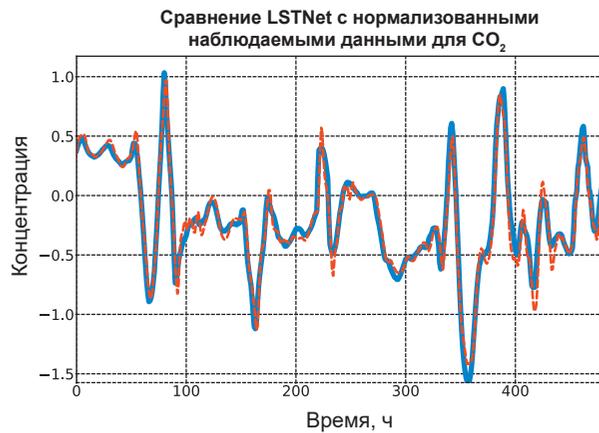
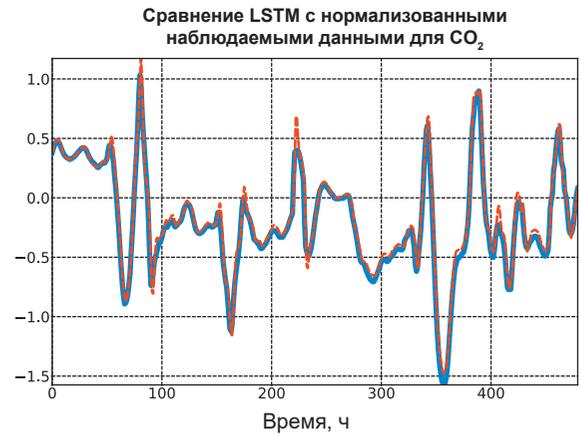
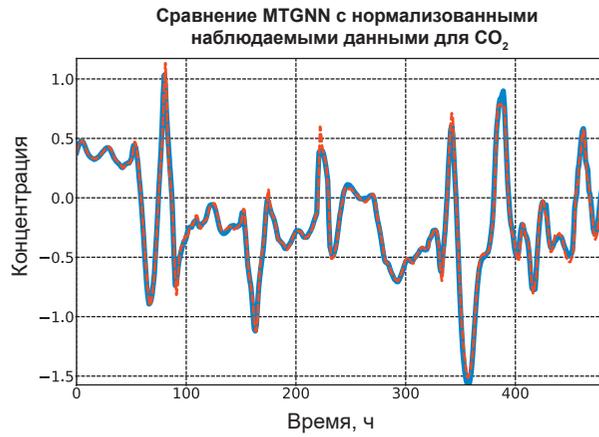
— Наблюдаемые значения
 - - - Предсказанные значения

Рис. 2. Прогноз моделей для динамики CH_4 .
 Составлено авторами
 Fig. 2. Model forecast for CH_4 dynamics.
 Compiled by the authors



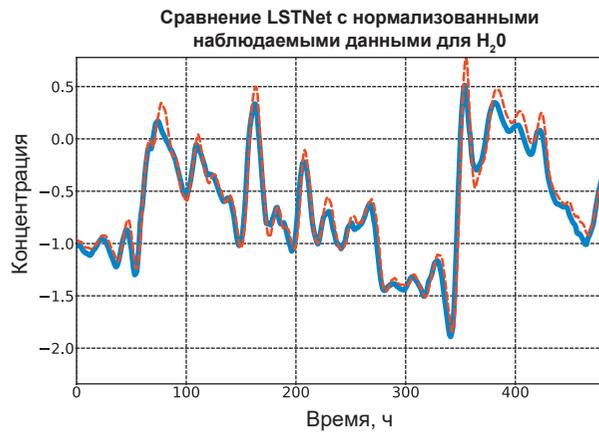
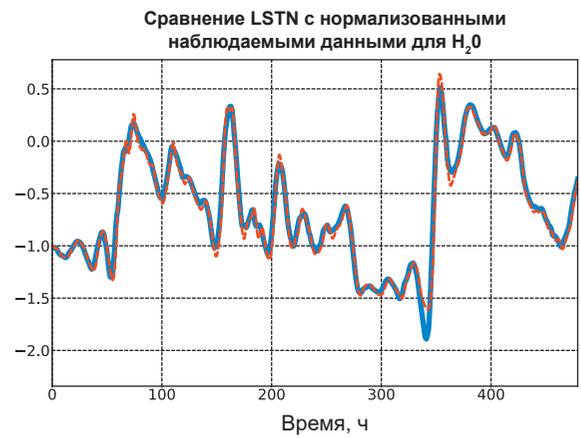
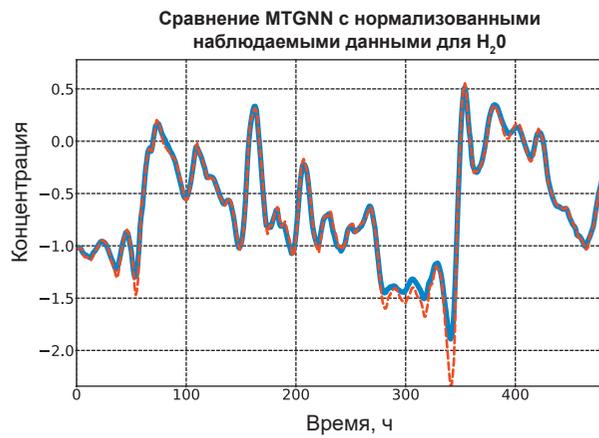
— Наблюдаемые значения
 - - - Предсказанные значения

Рис. 3. Прогноз моделей для динамики CO .
 Составлено авторами
 Fig. 3. Model forecast for CO dynamics.
 Compiled by the authors



— Наблюдаемые значения
- - - Предсказанные значения

Рис. 4. Прогноз моделей для динамики CO₂.
Составлено авторами
Fig. 4. Model forecast for CO₂ dynamics.
Compiled by the authors



— Наблюдаемые значения
- - - Предсказанные значения

Рис. 5. Прогноз моделей для динамики H₂O.
Составлено авторами
Fig. 5. Model forecast for H₂O dynamics.
Compiled by the authors

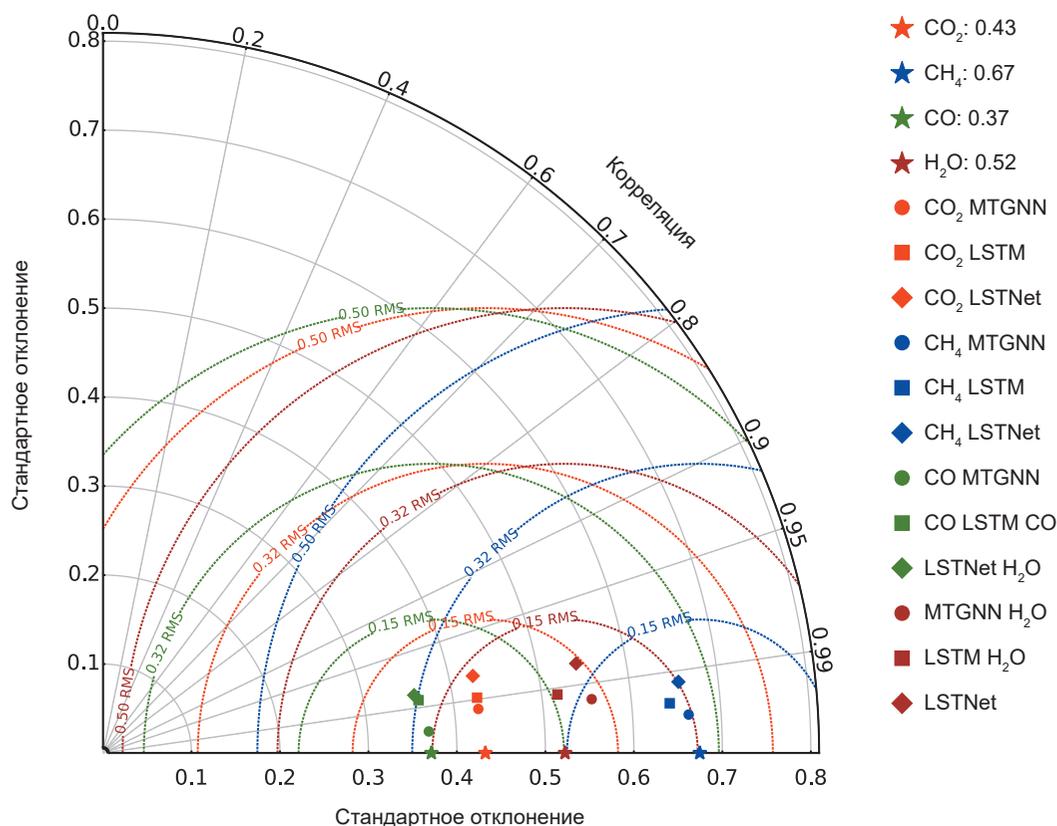


Рис. 6. Диаграмма Тейлора, построенная по нормализованным данным. Составлено авторами
 Fig. 6. Taylor diagram plotted from normalized data. Compiled by the authors

Диаграмма Тейлора позволила оценить, насколько точно предложенные модели прогноза воспроизводят каждый из четырех наблюдаемых временных рядов. Построенная диаграмма объединяет стандартное отклонение, коэффициент корреляции и стандартное отклонение всех прогнозных моделей (рис. 6).

Общий анализ показывает, что модель MTGNN демонстрирует наилучшие результаты по всем показателям. Она стабильно обеспечивает наибольшую корреляцию с эталонными данными, близкое стандартное отклонение и наименьшую RMS-ошибку. Особенно хорошо MTGNN справляется с прогнозированием CO₂ и CH₄, где ее точки находятся ближе всего к эталонным значениям на диаграмме. Также она уверенно лидирует при прогнозировании H₂O и показывает умеренно хорошие результаты по CO, где в целом качество предсказаний всех моделей ниже. Модель LSTM занимает промежуточную позицию: она уступает MTGNN, но зачастую опережает LSTNet. LSTNet, в свою очередь, демонстрирует наихудшие результаты по всем четырем газам — ее предсказания менее точны, корреляция ниже, а RMS-ошибка выше. Таким образом, из всех протестированных моделей MTGNN является наиболее точной и стабильной архитектурой для прогнозирования динамики концентраций газов за исследуемый период.

Одним из ограничений подхода на основе MTGNN стало увеличение времени обучения и количества параметров по сравнению с рекуррентными методами, что согласуется с тем, что графовые сети обычно требуют большего объема вычислительных ресурсов. Предполагается, что эти ограничения могут быть ослаблены путем использования нескольких техник оптимизации: подвыборки данных, мини-батчинга, агрегации временных признаков, сжатия признаков, оптимизации архитектуры модели, динамического распределения памяти, сжатия и квантования весов, методов кросс-валидации и регуляризации. Например, агрегация временных признаков позволяет хранить усредненные или максимальные значения за фиксированные временные интервалы, а мини-батчинг подразумевает обработку сегментов временного ряда небольшими порциями, что снижает нагрузку на память. Сжатие признаков (PCA и прочие методы) уменьшает размерность, а оптимизация архитектуры, включая рекуррентные слои или дополнительные механизмы сжатия весов, помогает ускорить обучение и сократить количество используемых ресурсов.

В текущем исследовании для обработки временных рядов применялось «окно выборки», позволяющее анализировать только недавние и текущие значения, а не весь ряд. Подвыборка данных также может повысить эффективность, так как сни-

жает частоту измерений, беря значения через регулярные интервалы.

Заключение

В работе приведено сравнение графовых и рекуррентных методов для прогнозирования динамики временных рядов естественного происхождения на примере приземной концентрации четырех газов CO_2 , CH_4 , CO и H_2O , измеренных на острове Белый за летние месяцы 2016—2017 гг. Рекуррентные нейронные сети были представлены моделями LSTM и LSTNet, графовый подход — моделью MTGNN, на вход которой подавались данные в виде графов, полученные из исходных временных рядов. Сравнение моделей выявило преимущества и ограничения графовых методов по сравнению с традиционными архитектурами, что позволило более полно оценить их потенциал в задачах прогнозирования временных рядов. Полученные результаты показывают, что хотя рекуррентные модели конкурентоспособны в задачах прогнозирования многомерных временных рядов, использование графовых нейронных сетей открывает более широкие перспективы при увеличении объемов данных и усложнении межсерийных связей. Несмотря на требования больших вычислительных ресурсов и времени обучения, грамотно сконструированные GNN позволяют точнее улавливать структурные зависимости во временных рядах и дают более стабильные прогнозы без дополнительной ручной постобработки.

Модели LSTM, LSTNet и MTGNN в данной работе ориентированы на краткосрочное прогнозирование концентраций газов (окна 48—96 отсчетов, что соответствует нескольким суткам при почасовой дискретизации). Причина в следующем:

- Рекуррентные и графовые модели хорошо улавливают локальные и среднесрочные зависимости, но при экстраполяции на длительные горизонты (месяцы-год) ошибки прогнозов накапливаются, что снижает точность. Для долгосрочного прогноза потребуются либо модели, специально обученные на многолетних данных, либо гибридные подходы с сезонными и трендовыми компонентами.
- Число входных признаков и длина окна ограничивают способность моделей захватывать долгосрочные циклы и редкие события, которые проявляются на временных интервалах больше года.

В заключение необходимо отметить, что при сопоставимой точности прогнозов архитектуры, основанные на графах, как показала модель MTGNN, обладают более широким потенциалом при возрастании объема и сложности данных благодаря учету структурных взаимосвязей между переменными. Таким образом, графовые нейронные сети могут оказаться более эффективными для решения сложных задач прогнозирования динамики временных рядов, хотя это и сопряжено с большими вычислительными затратами.

Финансирование

Исследование выполнено за счет субсидий Минобрнауки РФ на выполнение научной темы FUMN-2024-0003.

Благодарность

Авторы признательны Центру коллективного пользования арктических экологических исследований Института промышленной экологии Уральского отделения РАН за предоставление аппаратуры для измерения концентрации парниковых газов на острове Белый. Также авторы выражают благодарность рецензентам за конструктивные комментарии.

Литература/References

1. Liu J., Ma Z. Forecasting Housing Price Using GRU, LSTM and Bi-LSTM for California. 2024 IEEE 2nd International Conference on Control, Electronics and Computer Technology (ICCECT). [S. l.], 2024, pp. 1033—1037.
2. He Z., Zhao C., Huang Y. Multivariate Time Series Deep Spatiotemporal Forecasting with Graph Neural Network. *Applied Sciences*, 2022, vol. 12 (11), p. 5731.
3. Widiasari I. R., Efendi R. Utilizing LSTM-GRU for IOT-Based Water Level Prediction Using Multi-Variable Rainfall Time Series Data. *Informatics*, 2024, vol. 11 (4), p. 73.
4. Sangeetha S. K. B., Mathivanan K. M., Rajadurai H., Jaehyuk C., Sathishkumar V. E. A multi-modal geospatial-temporal LSTM based deep learning framework for predictive modeling of urban mobility patterns. *Scientific Reports*, 2024, vol. 14, p. 31579.
5. Zhang X., Tian Z., Shi Y., Guan Q., Lu Y., Pan Y. ST-FGCN: Spatio-Temporal Fusion Graph Convolutional Networks for Subway Traffic Prediction. *IEEE Access*, 2024, vol. 12, pp. 194449—194461.
6. Dai Z., Wang C., Hu D., Chen J., Fu S. Intercity round-trip multi-region demand prediction based on multi-task fusion recurrent graph attention network. *Neural Computing & Applications*, 2025, vol. 37, pp. 14829—14848.
7. Jiang W., Luo J. Graph neural network for traffic forecasting: A survey. *Expert Systems with Applications*, 2022, vol. 207, p. 117921.
8. Cheng K., Ye J., Lu X., Sun L., Du B. Temporal Graph Network for continuous-time dynamic event sequence. *Knowledge-Based Systems*, 2024, vol. 304, p. 112452.
9. Liang Y., Zhang W., Sheng Z., Yang L., Xu Q., Jiang J., Tong Y., Cu B. Towards Scalable and Deep Graph Neural Networks via Noise Masking. *arXiv preprint*, 2025, 2412.14602.
10. Li C., Li S., Gao Y., Zhou L., Li W. Static graph convolution with learned temporal and channel-wise graph topology generation for skeleton-based action recognition. *Computer Vision and Image Understanding*, 2024, vol. 244, p. 104012.
11. Bui K. N., Cho J., Yi H. Spatial-temporal graph neural network for traffic forecasting: An overview and open

research issues. *Applied Intelligence*, 2022, vol. 52, pp. 2763—2774.

12. Wu Z., Pan S., Chen F., Long G., Zhang C., Yu P. S. A Comprehensive Survey on Graph Neural Networks. *IEEE Transactions on Neural Networks and Learning Systems*, 2021, vol. 32 (1), pp. 4—24.

13. Wu F., Souza A., Zhang T., Fifty C., Yu T., Weinberger K. Simplifying Graph Convolutional Networks. *Proceedings of the 36th International Conference on Machine Learning*, PMLR, 2019, vol. 97, pp. 6861—6871.

14. Бувич 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.

Buevich A. G., Sergeev A. P., Shichkin A. V., Baglaeva E. M., Subbotina I. E., Butorova A. S. Model for predicting surface methane concentration in the Arctic region based on an artificial neural network with a long chain of short-term memory elements and wavelet transform of the initial data. *Arctic: Ecology and Economy*, 2023, vol. 13, no. 3, pp. 428—436. (In Russian).

15. 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 & Applications*, 2021, vol. 33, pp. 1547—1557.

16. Baglaeva E., Buevich A., Sergeev A., Rakhmatova A., Shichkin A. Forecasting of some greenhouse gases content trend in the air of the Russian Arctic region. *Atmospheric Pollution Research*, 2021, vol. 12 (3), pp. 68—75.

17. Богоявленский В. И., Сизов О. С., Никонов Р. А. *и др.* Дегазация земли в Арктике: генезис природной и антропогенной эмиссии метана // *Арктика: экология и экономика*. — 2020. — № 3 (39). — С. 6—22.

Bogoyavlensky V. I., Sizov O. S., Nikonov R. A., Bogoyavlensky I. V., Kargina T. N. Land degassing in the Arctic: genesis of natural and anthropogenic methane emissions. *Arctic: Ecology and Economy*, 2020, no. 3 (39), pp. 6—22. (In Russian).

18. Богоявленский В. И., Сизов О. С., Никонов Р. А., Богоявленский И. В. Мониторинг изменений концентрации метана в атмосфере Арктики в 2019—2021 гг. по данным спектрометра TROPOMI // *Арктика: экология и экономика*. — 2022. — Т. 12, № 3. — С. 304—319.

Bogoyavlensky V. I., Sizov O. S., Nikonov R. A., Bogoyavlensky I. V. Monitoring changes in methane concentration in the Arctic atmosphere in 2019—2021 according to TROPOMI spectrometer data. *Arctic: Ecology and Economy*, 2023, vol. 12, no. 3, pp. 304—319. (In Russian).

19. Серых И. В., Толстиков А. В. Климатические изменения температуры воздуха западной части российской Арктики в 1940—2099 гг. по данным ERA5 и моделям CMIP6 // *Арктика: экология и экономика*. — 2024. — Т. 14, № 3. — С. 334—349.

Serykh I. V., Tolstikov A. V. Climatic changes in air temperature in the western part of the Russian Arctic in 1940—2099 according to ERA5 data and CMIP6 models. *Arctic: Ecology and Economy*, 2024, vol. 14, no. 3, pp. 334—349. (In Russian).

20. Субботина И. Е., Баглаева Е. М., Бувич А. Г. *и др.* Динамика содержания парниковых газов в приземном слое атмосферного воздуха арктического острова Белый в летний период 2015—2017 гг. // *Арктика: экология и экономика*. — 2022. — Т. 12, № 1. — С. 68—76.

Subbotina I. E., Baglaeva E. M., Buevich A. G., Sergeev A. P., Shichkin A. V. Dynamics of greenhouse gas content in the surface layer of atmospheric air of the Arctic Bely Island in the summer period 2015—2017. *Arctic: Ecology and Economy*, 2022, vol. 12, no. 1, pp. 68—76. (In Russian).

21. Баглаева Е. М., Сергеев А. П., Бувич А. Г. *и др.* Непараметрическая оценка прогностической точности моделей на примере временных рядов концентраций метана в атмосферном воздухе арктического острова Белый // *Арктика: экология и экономика*. — 2024. — Т. 14, № 4. — С. 500—510.

Baglaeva E. M., Sergeev A. P., Buevich A. G., Shichkin A. V., Subbotina I. E. Nonparametric assessment of the predictive accuracy of models using the example of time series of methane concentrations in the atmospheric air of the Arctic Island Bely. *Arctic: Ecology and Economy*, 2024, vol. 14, no. 4, pp. 500—510. (In Russian).

Информация об авторах

Бобаков Вениамин Сергеевич, лаборант, Институт промышленной экологии Уральского отделения РАН (620990, Россия, Екатеринбург, ул. Софьи Ковалевской, д. 20), e-mail: veniabobakov97@gmail.com.

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

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

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

COMPARATIVE ANALYSIS OF NEURAL NETWORK MODELS FOR FORECASTING THE DYNAMICS OF GREENHOUSE GAS CONCENTRATIONS IN THE SURFACE AIR LAYER ON BELY ISLAND

Bobakov, V. C., Buevich, A. G., Butorova, A. S., Sergeev, A. P.

Institute of Industrial Ecology of Ural Branch of the Russian Academy of Sciences (Yekaterinburg, Russian Federation)

The article was received on July 23, 2025

For citing

Bobakov V. C., Buevich A. G., Butorova A. S., Sergeev A. P. Comparative analysis of neural network models for forecasting the dynamics of greenhouse gas concentrations in the surface air layer on Bely Island. *Arctic: Ecology and Economy*, 2026, vol. 16, no. 1, pp. 53—63. DOI: 10.25283/2223-4594-2026-1-53-63. (In Russian).

Abstract

In recent years, the application of machine learning technologies has become increasingly relevant for monitoring greenhouse gas emissions in the Arctic, where intense permafrost degradation and increasing methane emissions into the atmosphere are observed. In the study, we have developed and compared recurrent and graph neural network-based models to predict the dynamics of concentrations of major greenhouse gases in the surface air on Bely Island, the Yamalo-Nenets Autonomous Area, Russia. The original dataset consisted of surface concentration measurements of four gases for the summer months of 2016—2017: carbon dioxide (CO₂), methane (CH₄), carbon monoxide (CO), and water vapor (H₂O). For graph forecasting, we used the Multivariate Time Series Graph Neural Network (MTGNN) model; for recurrent forecasting, we used the Long Short-Term Memory (LSTM) and Long Short-Term Memory Network (LSTNet) models. The forecast accuracy of the models was assessed using the following metrics: mean absolute error (MAE), root mean square error (RMSE), normalized root mean square error (NRMSE), and correlation coefficient (Corr). In general, the MTGNN model demonstrated lower error values compared to recurrent models (LSTM, LSTNet). Compared to LSTM and LSTNet, MTGNN had 25—55% lower errors. The more accurate graph model required significantly more time to train and had a significantly larger number of parameters for optimization.

Keywords: *time series, greenhouse gases, Arctic, forecast, neural networks, graph neural networks, LSTM.*

Funding

The study was supported by Ministry of Science and Higher Education of the Russian Federation, project FUMN-2024-0003.

Acknowledgements

The authors are grateful to the Center for Collective Use of Arctic Environmental Research at the Institute of Industrial Ecology of the Ural Branch of the Russian Academy of Sciences for providing equipment for measuring greenhouse gas concentrations on Bely Island. The authors also thank the reviewers for their constructive comments.

Information about the authors

Bobakov, Veniamin Sergeevich, Laboratory Assistant, Institute of Industrial Ecology, Ural Branch of the Russian Academy of Sciences (20, S. Kovalevskaya St., Yekaterinburg, Russia, 620990), e-mail: veniabobakov97@gmail.com.

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

Butorova, Anastasia Sergeevna, Junior Researcher, Institute of Industrial Ecology, Ural Branch of the Russian Academy of Sciences (20, S. Kovalevskaya St., Yekaterinburg, Russia, 620990), e-mail: amoskalyova03@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. Kovalevskaya St., Yekaterinburg, Russia, 620990), e-mail: aleksandrpsergeev@gmail.com.