

Гибридная модель прогнозирования полного электронного содержания ионосферы на основе автокодировщиков и классических алгоритмов машинного обучения

А. М. Аппалонов¹✉, Ю. С. Масленникова¹

¹Казанский (Приволжский) Федеральный Университет, Казань, Россия
E-mail: ✉artem309_97@mail.ru

Поступила в редакцию 28.11.2025, принята к публикации 25.12.2025,
опубликована онлайн 26.12.2025

Аннотация. В данной работе предложен двухэтапный алгоритм машинного обучения для прогнозирования значений полного электронного содержания (ПЭС). На первом этапе выполняется снижение размерности исходных временных рядов ПЭС с использованием стандартного полносвязного автокодировщика. Это позволяет выделить сжатые латентные представления, которые сохраняют ключевые временные зависимости и паттерны данных. На втором этапе эти латентные признаки объединяются с набором внешних параметров, влияющих на состояние ионосферы: критической частотой слоя F2 (foF2), индексами солнечной (F10.7) и геомагнитной (Kp) активности, а также временными метками (время года, время суток). Полученный обогащенный набор данных используется для обучения и тестирования нескольких классических алгоритмов машинного обучения, включая градиентный бустинг. Показано, что алгоритм CatBoost демонстрирует наилучшую точность прогноза на тестовой выборке по сравнению с другими моделями, что подтверждается метриками RMSE и MAE. Предложенный метод обеспечивает точный и эффективный прогноз ПЭС, объединяя преимущества нейросетевого сжатия данных и мощь современных ансамблевых алгоритмов.

Ключевые слова: ионосфера, полное электронное содержание, карты ПЭС, солнечная активность, машинное обучение, нейронные сети, автокодировщик, экваториальная аномалия.

Для цитирования: Аппалонов А. М., Масленникова Ю. С. Гибридная модель прогнозирования полного электронного содержания ионосферы на основе автокодировщиков и классических алгоритмов машинного обучения // Известия вузов. ПНД. 2026. DOI: 10.18500/0869-6632-003207. EDN: QKRVJO

Статья опубликована на условиях Creative Commons Attribution License (CC-BY 4.0).

A hybrid total electron content forecasting model based on autoencoders and classical machine learning algorithms

A. M. Appalonov¹✉, Y. S. Maslennikova¹

¹Kazan Federal University, Kazan, Russia

E-mail: ✉artem309_97@mail.ru

Received 28.11.2025, accepted 25.12.2025, available online 26.12.2025

Abstract. This paper presents a novel two-stage machine learning algorithm designed for total electron content forecasting. In the first stage, dimensionality reduction of the original TEC time series is performed using a standard fully-connected autoencoder. This process extracts compressed latent representations that encapsulate the essential temporal patterns and dependencies. In the second stage, these latent features are integrated with a set of external parameters known to influence ionospheric conditions: the critical frequency of the F2 layer (foF2), indices of solar (F10.7) and geomagnetic (Kp) activity, and temporal descriptors (seasonal and diurnal information). The resulting enriched feature set is used to train and evaluate several classical machine learning algorithms. Comparative analysis reveals that the CatBoost algorithm demonstrates superior predictive accuracy on the test dataset, outperforming other models as validated by Root Mean Square Error (RMSE) and Mean Absolute Error (MAE) metrics. The proposed method provides a robust and effective framework for TEC prediction, successfully leveraging the strengths of neural network-based feature extraction and the power of modern ensemble learning techniques.

Keywords: Ionosphere, total electronic content, TEC maps, solar activity, machine learning, neural networks, auto-coder, equatorial anomaly.

For citation: Appalonov AM, Maslennikova YS. A hybrid total electron content forecasting model based on autoencoders and classical machine learning algorithms. Izvestiya VUZ. Applied Nonlinear Dynamics. 2026. DOI: 10.18500/0869-6632-003207

This is an open access article distributed under the terms of Creative Commons Attribution License (CC-BY 4.0).

Введение

Ионосфера Земли, представляющая собой ионизированную часть верхней атмосферы, играет критически важную роль в распространении радиоволн и функционировании современных технологических систем. Ключевым параметром, интегрально характеризующим состояние ионосферы, является полное электронное содержание (ПЭС) [1]. Колебания ПЭС оказывают существенное влияние на точность и надёжность работы спутниковых навигационных систем (таких как ГЛОНАСС и GPS), систем связи и дистанционного зондирования Земли. Внезапные возмущения ПЭС, вызванные солнечной и геомагнитной активностью, могут приводить к значительным ошибкам позиционирования, ухудшению качества связи и даже сбоям в работе энергетических сетей [2,3]. В связи с этим задача разработки точных и надёжных методов прогнозирования состояния ионосферы, и ПЭС, в частности, сохраняет высокую актуальность для фундаментальной науки и практических приложений.

Традиционные подходы к моделированию ионосферы можно условно разделить на физические и эмпирические. Физические модели, основанные на решении сложных систем уравнений, описывающих физико-химические процессы в ионосфере, требуют значительных вычислительных ресурсов и зачастую не успевают за быстротекущими изменениями в ней [4]. Эмпирические модели, строящиеся на статистическом анализе больших архивов данных, обладают большей оперативностью, но могут недостаточно точно учитывать спе-

цифику конкретных геофизических условий. Оба подхода сталкиваются с трудностями при описании нелинейных и нестационарных временных рядов, каковыми являются данные измерений ПЭС [5, 6].

В последнее время машинное обучение (МО) демонстрирует значительный потенциал в решении задач прогнозирования временных рядов в геофизике. Алгоритмы, такие как метод опорных векторов (SVM), случайный лес и градиентный бустинг, успешно применяются для моделирования ПЭС [7]. Однако эффективность этих методов напрямую зависит от качества и репрезентативности признакового пространства. Исходные временные ряды ПЭС характеризуются высокой размерностью, наличием шумов и сложными временными зависимостями, что затрудняет их непосредственное использование в классических алгоритмах МО. Это обуславливает необходимость этапа предварительной обработки данных и выделения информативных признаков.

Одним из мощных методов снижения размерности и выделения скрытых паттернов в данных являются автокодировщики [8]. Эти нейронные сети способны обучаться сжатому представлению исходных данных, отфильтровывая шумы и сохраняя наиболее существенные зависимости. В отличие от свёрточных сетей, ориентированных на пространственные паттерны, полносвязные автокодировщики хорошо приспособлены для работы с временными рядами, позволяя эффективно сокращать их размерность без потери значимой информации. Полученные на их выходе латентные представления формируют компактное и информативное описание динамики ионосферных процессов.

Кроме того, состояние ионосферы зависит от множества внешних факторов. К ним относятся параметры, характеризующие солнечную активность (такие как индекс F10.7), геомагнитную возмущённость (индекс Kp), а также ключевые ионосферные характеристики, например, критическая частота слоя F2 (f_oF2). Суточные и сезонные вариации также вносят значительный вклад в изменчивость ПЭС. Таким образом, объединение латентных представлений временных рядов ПЭС с релевантными внешними признаками позволяет создать комплексное признаковое пространство, значительно повышающее потенциал моделей прогнозирования.

Целью настоящего исследования является разработка гибридной модели прогнозирования полного электронного содержания ионосферы, сочетающей в себе методы глубокого обучения для выделения ключевых признаков и классические алгоритмы машинного обучения для конечной регрессии.

Решаемые задачи:

1. построение и обучение полносвязного автокодировщика для компрессии временных рядов ПЭС и выделения латентных признаков;
2. формирование расширенного набора данных путём объединения этих признаков с внешними геофизическими и временными параметрами;
3. сравнительный анализ эффективности различных классических алгоритмов МО, включая градиентный бустинг, на расширенном наборе данных.

1. Архитектура нейронной сети для снижения размерности данных

1.1. Обоснование выбора архитектуры нейронной сети Для эффективного решения задачи прогнозирования параметров ионосферы критически важным этапом является корректная подготовка признакового пространства. Исходные данные, включающие временные ряды карт полного электронного содержания (ПЭС) и значений критической частоты слоя F2 (f_oF2), характеризуются высокой размерностью, наличием шумов и слож-

ными нелинейными зависимостями. Прямое использование таких данных для классических алгоритмов машинного обучения часто приводит к переобучению и снижению обобщающей способности моделей. В связи с этим в данной работе применяется подход на основе автокодировщика (autoencoder) — специальной архитектуры нейронной сети, предназначенной для эффективного снижения размерности данных и выделения наиболее значимых латентных признаков.

Основная задача, решаемая на данном этапе, заключалась в нелинейном сжатии исходного пространства признаков до компактного векторного представления размерностью 10 элементов. Это позволяет существенно сократить вычислительную сложность последующего анализа, отфильтровать шумы и выделить инвариантные представления, сохраняющие ключевую информацию о динамике ионосферных процессов.

1.2. Структура автокодировщика Предложенная архитектура автокодировщика представляет собой последовательную модель, состоящую из двух симметричных частей: энкодера (кодировщика) и декодера (декодировщика).

Входной вектор модели представляет собой конкатенацию «распрямлённой» ($M \times N \rightarrow M \cdot N$) целевой карты ПЭС и соответствующей ей растянутой карты значений foF2, построенной для того же момента времени. Использование этой дополнительной пространственной информации улучшает качество реконструкции [9].

Главное преимущество данного подхода заключается в его способности выявлять сложные нелинейные зависимости в данных и извлекать наиболее информативные признаки автоматически, без явного задания правил преобразования. В отличие от традиционных методов снижения размерности, таких как анализ главных компонент, автокодировщики способны учитывать сложные структурные особенности данных, включая иерархические зависимости между признаками.

Особую ценность автокодировщики представляют при работе с пространственно-временными данными, такими как глобальные карты ионосферных параметров. В этом случае они позволяют не только эффективно снижать размерность данных, но и выявлять скрытые паттерны и аномалии, которые трудно обнаружить традиционными методами.

Исходный набор данных был разделён в пропорции 80:20 для целей обучения модели и последующей оценки её результатов: 87 600 карт ПЭС (80%) выделены целенаправленно для тренировочного этапа, тогда как оставшиеся 21 900 карт (20%) использованы для процедуры валидации алгоритма.

Следует подчеркнуть, что векторы, полученные на скрытом слое автокодировщика, могут демонстрировать наличие взаимосвязей (коррелировать), что, в свою очередь, может негативно сказаться на качестве и интерпретируемости разложения. В данной работе для достижения ортогональности векторов была применена дополнительная структура, которая инициализирует веса скрытого слоя линейного преобразования с использованием ортогональной матрицы, полученной через QR-разложение [9].

Количество скрытых слоёв было выбрано 10, так как было показано ранее, именно они несут в себе более 95% исходной информации об исходных данных [8].

После завершения обучения кодировщик и декодировщик могут быть использованы независимо. Для формирования признакового пространства для последующих моделей машинного обучения (например, CatBoost) использовался только обученный энкодер. Все исходные данные (временные ряды ПЭС и foF2) пропускались через энкодер, и на выходе получались соответствующие им 10-мерные латентные векторы. Именно эти векторы, являющиеся сжатым и информативным представлением исходного состояния ионосферы, в дальнейшем использовались в качестве входных признаков для алгоритмов прогнозирования.




Рис. 1. Выбранная архитектура для сжатия исходного пространства входных признаков [9].
Fig. 1. The chosen architecture for compression of the original input feature space [9].

ния. Данный подход позволяет не только резко сократить размерность данных, но и передавать моделям машинного обучения уже очищенные и семантически насыщенные признаки, что в конечном итоге повышает точность и надёжность прогноза.

Ключевые технические параметры: сжатие исходных данных происходит до 10 скрытых векторов, используется функции активации ReLU (Rectified Linear Unit, «Выпрямленный линейный блок») во внутренних слоях, пакетная нормализация после каждого линейного слоя для стабилизации обучения, и дропаут (0.2) для регуляризации. Функция потерь состоит из MSE (Mean Squared Error, среднеквадратичная ошибка) для реконструкции. Оптимизация выполняется с помощью метода AdamW с L2-регуляризацией (затухание весов равно $1e-5$) и скоростью обучения, равной 0.001.

2. База данных

2.1. Данные полного электронного содержания (ПЭС) В качестве исходных данных о состоянии ионосферы использовались карты полного электронного содержания (Total Electron Content, TEC), предоставляемые Лабораторией реактивного движения NASA (Jet Propulsion Laboratory, JPL) [10]. Данные JPL GIM (Global Ionosphere Maps) являются одним из наиболее точных и широко используемых в мировом научном сообществе продуктов, характеризующих интегральное электронное содержание в вертикальном столбе ионосферы. Карты представлены в формате IONEX с временным разрешением 2 часа и пространственным разрешением 2.5° по долготе и 5° по широте.

Предварительная обработка временных рядов TEC для конкретной локации включала следующие этапы:

1. извлечение временного ряда: для выбранной точки с заданными географическими ко-




Рис. 2. Карта ПЭС ионосферы, полученная лабораторией JPL [10].
Fig. 2. JPL ionospheric TEC map [10].

ординатами из последовательности глобальных карт извлекался временной ряд значений вертикального ПЭС;

2. идентификация и интерполяция пропусков: временной ряд проверялся на наличие пропусков данных, которые могли быть вызваны сбоями в работе спутниковой группировки или процессе обработки. Незначительные пропуски восстанавливались с помощью линейной интерполяции;
3. сглаживание: для подавления высокочастотного шума, не связанного с крупномасштабными ионосферными процессами, применялось скользящее среднее с окном, соответствующим 6 часам;
4. формирование выборки: обработанные временные ряды ПЭС служили основой для построения признаков, описывающих текущее состояние ионосферы.

2.2. Данные о значениях критической частоты слоя F2 (foF2) Для дополнения признакового пространства параметрами, непосредственно характеризующими максимальную электронную плотность ионосферы, использовались данные о критической частоте слоя F2 (foF2). Эти данные были получены из глобальной сети ионозондов GIRO (Global Ionospheric Radio Observatory) [11]. GIRO предоставляет доступ к результатам вертикального зондирования ионосферы с большого количества станций по всему миру, что позволяет получать репрезентативные данные о ключевых параметрах ионосферы, включая foF2.

Предварительная обработка данных foF2 включала:

1. сопоставление по местоположению и времени: данные foF2 выбирались для ионозондной станции, наиболее близко расположенной к точке, для которой извлекался ряд ПЭС. Временные метки данных foF2 приводились в соответствие с временными метками данных JPL ПЭС;
2. восстановление пропусков: поскольку данные ионозондов могут иметь значительные



Рис. 3. Расположение сети глобальных ионосферных станций GIRO (январь 2020) [11].

Fig. 3. Location of the GIRO (Global Ionospheric Radio Observatory) network of global ionospheric stations (January 2020) [11].

пропуски (например, из-за технических неисправностей или плохих условий распространения радиоволн), для реконструкции недостающих значений применялся алгоритм интерполяции по ближайшим соседним станциям сети GIRO с последующей временной интерполяцией.

2.3. Формирование итогового набора данных Обработанные временные ряды ПЭС и foF2 были объединены с данными о солнечной (индекс F10.7) и геомагнитной активности (индексы Kp), полученными из открытых источников (DRAO, Leibniz Institute for Astrophysics Potsdam) [12, 13]. В более ранних работах было показано, что они коррелируют с извлекаемыми рядами ПЭС [14]. Также в качестве признаков были добавлены циклические временные характеристики: время года и время суток. Итоговый набор данных представлял собой таблицу, где каждый экземпляр содержал латентные представления ПЭС (обогащенный значениями foF2), внешние индексы и временные метки, что позволило применить для прогнозирования классические алгоритмы машинного обучения.

3. Обсуждение результатов

Ниже представлена блок-схема предложенного подхода, в которой отображены основные этапы обработки и изменения данных.

3.1. Отбор признаков В нашем случае были взяты следующие признаки, которые могут повлиять на предсказание значений временных составляющих ПЭС:

- временные лаги исходного ряда (за последние 72 часа) — это позволяет уловить изменения, которые претерпевает электронная концентрация (в том числе флуктуации значений);

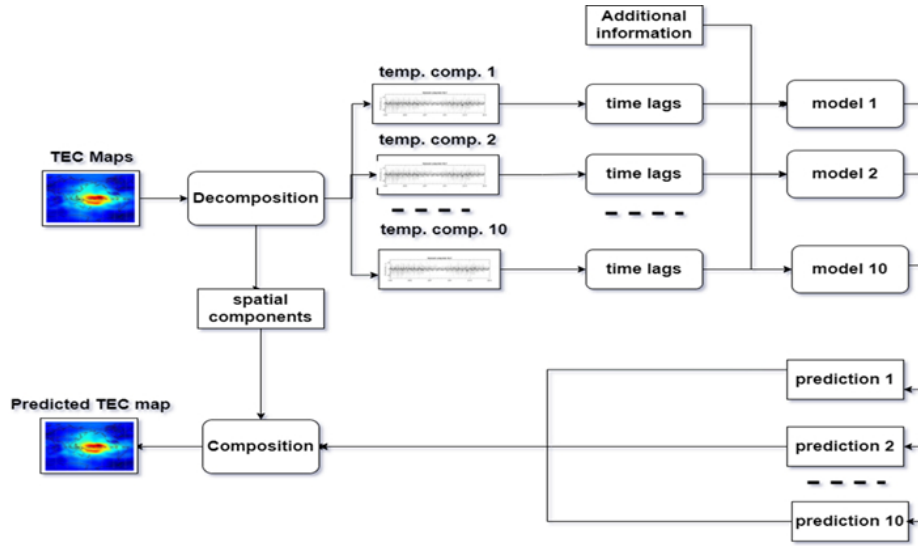


Рис. 4. Блок-схема предложенного подхода [15].
Fig. 4. Flowchart of the proposed approach [15].

- месяц, день и час даты, на которую делается прогноз;
- значение индекса F10.7 в момент, когда делается прогноз;
- значение индекса Kp в момент, когда делается прогноз.

Временные лаги, которые приведены первыми в списке признаков, являются, по сути, гиперпараметром, который настраивается при инференсе. Здесь важно найти оптимальное сочетание для того, чтобы количество лагов не сильно увеличивало время выполнения прогноза, но смогло бы повысить точность. Временные ряды отсчётов радиофизических приборов в задачах геофизики имеют свою специфичность, которую тоже нужно учитывать при отборе признаков для моделей машинного обучения. Ниже приведена таблица, где представлены ошибка по метрике SMAPE и время прогноза на инференсе для полученного лучшего алгоритма (по результатам таблицы 2).

Метрика SMAPE определяется как

$$\text{SMAPE} = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{(|y_i| + |\hat{y}_i| + \varepsilon) / 2}, \quad (1)$$

где y_i — фактическое значение, а \hat{y}_i — прогнозируемое значение, $\varepsilon = 10^{-8}$ — для обеспечения численной устойчивости при значениях, близких к нулю (обеспечивает универсальность данного выражения).

SMAPE является стандартной и общепризнанной метрикой в прогнозировании временных рядов, особенно в бизнес-аналитике (прогнозирование спроса, продаж, нагрузки) [16].

3.2. Обучение и валидация моделей Критически важным аспектом при работе с временными рядами является корректное разделение данных на обучающую и тестовую выборки. В отличие от задач, где данные независимы и распределены одинаково, в временных рядах присутствует сильная временная зависимость (автокорреляция). Произволь-

Таблица 1 Количество лагов для реализации алгоритма прогнозирования (для первой компоненты временного разложения автокодировщика).
 Table 1. Number of lags for the implementation of the forecasting algorithm (for the first component of the temporal decomposition of the autoencoder).

Количество лагов, часы	SMAPE	Время выполнения прогноза, с
24	0.21	0.35
48	0.14	0.72
72	0.06	0.91
96	0.06	1.2

ное перемешивание и случайное разделение данных в таком случае привело бы к «утечке информации из будущего в прошлое»: модель, обучаясь на данных из всего временного интервала, могла бы косвенно получать информацию о будущих состояниях системы при прогнозировании прошлых, что исказило бы реальную оценку её обобщающей способности.

Во избежание этого было применено строгое временное разделение (temporal split). Первые 80% данных (87 600 векторов), соответствующих начальному временному периоду, были выделены в обучающую выборку. Оставшиеся 20% данных (21 900 векторов), хронологически следующие за обучающей выборкой, составили тестовую выборку. Такой подход гарантирует, что модель обучается исключительно на прошлых данных и проверяется на будущих, что полностью имитирует условия реальной эксплуатации и обеспечивает адекватную валидацию её прогностической эффективности.

Для сравнения моделей на этапе обучения и валидации были использованы следующие метрики: MAE (mean absolute error), MSE (mean squared error), RMSE (root mean squared error), коэффициент детерминации R^2 и уже описанная выше SMAPE.

Сравнение алгоритмов происходило как усреднённая ошибка всех 10 моделей (для каждой из компонент) для прогноза на 24 часа вперёд.

Таблица 2 Результаты обучения моделей машинного обучения (топ 5 наилучших алгоритмов).
 Table 2. Machine learning model training results (top 5 best algorithms).

Алгоритм	MAE	MSE	RMSE	R^2	SMAPE
CatBoost	1.9	11.8	3.4	0.98	0.25
XGBoost	2.1	15.2	3.9	0.98	0.27
LightGBM	3.1	17.2	4.1	0.98	0.28
ExtraTrees	3.2	17.2	4.1	0.97	0.29
Random Forest	3.4	18.2	4.2	0.97	0.30

Исходя из приведённой выше таблицы видно, что наилучшие результаты для признаков, полученных при помощи нейронной сети автокодировщика, показала одна из модификаций алгоритма градиентного бустинга CatBoost.

Ранее авторами была разработана модель снижения размерности для данных ПЭС на основе линейного метода главных компонент (МГК), которая показала свою базовую эффективность относительно используемых моделей [15]. Однако линейный характер преобразования в МГК может ограничивать его способность к выделению сложных нелинейных закономерностей, присущих ионосферной динамике. Чтобы количественно оценить преимущества нового подхода, был проведён сравнительный анализ прогностической эффективности гибридных моделей, использующих для генерации признаков как предложенный автокодировщик, так и ранее разработанную модель на основе МГК (количество сжатых векторов в обоих случаях равнялось 10).

Для оценки качества восстановленных карт была использована метрика WMAPE, которая позволяет учитывать пространственный вклад каждой отдельной прогнозируемой точки на карте:

$$\text{WMAPE} = \frac{\sum_{i=1}^n |y_i| \frac{|y_i - \hat{y}_i|}{|y_i|}}{\sum_{i=1}^n |y_i|}. \quad (2)$$

Результаты сравнения приведены в таблице ниже, где сопоставляются два подхода: на основе метода главных компонент (МГК) и автокодировщика (АК) [15].

Таблица 3 Результаты сравнения восстановленных карт на основе двух подходов.
Table 3. Results of comparison of reconstructed maps based on two approaches.

Период прогноза, часы	МГК	АК
2	0.21	0.15
4	0.25	0.17
12	0.27	0.20
24	0.31	0.23
48	0.41	0.31
72	0.51	0.35
144	0.61	0.42

Представленные в Таблице 3 значения метрики WMAPE рассчитаны для глобальной области покрытия карт ПЭС. Усреднение производится по всем пространственным ячейкам расчётной сетки. Такой подход к агрегации ошибки, в отличие от точечной или региональной оценки, позволяет учесть её пространственную неоднородность по всей области исследования. Это особенно критично для анализа качества моделей в ключевых с точки зрения физики ионосферы регионах, таких как зона экваториальной аномалии, где ошибки прогноза часто имеют систематический и повышенный характер. Следовательно, глобальная WMAPE даёт интегрированную и наиболее репрезентативную оценку производительности модели для задачи восстановления полей.

Выводы и заключение

В ходе проведённого исследования была успешно разработана и протестирована двух-этапная гибридная модель для прогнозирования параметров ионосферы, в частности полного электронного содержания (ПЭС). Ключевым элементом подхода явилось использование полносвязного автокодировщика для нелинейного снижения размерности исходных высокоразмерных данных, объединяющих временные ряды карт ПЭС и значения критической частоты слоя F2 (foF2). Это позволило эффективно сжать информацию, выделить наиболее значимые латентные признаки и устранить шумы, создав компактное 10-мерное пространство описания состояния ионосферы.

На втором этапе продемонстрировано, что полученные латентные представления, обогащённые данными о солнечной и геомагнитной активности, являются высокоэффективным признаковым пространством для классических алгоритмов машинного обучения. Сравнительный анализ показал, что алгоритм градиентного бустинга CatBoost демонстрирует наилучшую точность прогноза на тестовой выборке, что подтверждается метриками RMSE и

МАН. Важным условием достоверной оценки стала корректная процедура временного разделения данных, исключившая информационную утечку.

Таким образом, предложенная гибридная архитектура позволяет преодолеть ограничения, присущие как чисто физическим, так и эмпирическим моделям, что демонстрируют значения метрики WMAPE. Это может указывать на его потенциальное превосходство в сравнении с классическими методами. Сочетание глубоких нейронных сетей для выделения признаков и ансамблевых методов для регрессии открывает перспективное направление для создания точных и оперативных систем прогноза состояния ионосферы, что крайне востребовано для обеспечения надёжности спутниковой навигации и связи.

Список литературы

1. Брюнелли Б. Е., Намгаладзе А. А. Физика ионосферы. М.: Наука, 1988. 527 с.
2. Mendillo M. Storms in the ionosphere: Patterns and processes for total electron content // *Reviews of Geophysics*. 2006. Vol. 44, No. 4. DOI: 10.1029/2005RG000193.
3. Максимов Д. С., Козогин Д. А., Насыров И. А., Загреддинов Р. В. Солнечные вспышки в 25-м цикле активности: влияние на ионосферную возмущённость и мощность ГНСС-сигналов // *Современные проблемы дистанционного зондирования Земли из космоса*. 2025. Т. 22, № 3. С. 301–317.
4. Fitzgerald T. J. Observations of total electron content perturbation of GPS signals caused by a ground level explosion // *Journal of Atmospheric and Solar-Terrestrial Physics*. 1997. Vol. 59. P. 829–834.
5. Feng J. D., Zhang T., Li W. et al. A new global TEC empirical model based on fusing multi-source data // *GPS Solutions*. 2023. Vol. 27, Iss. 1. P. 20. DOI: 10.1007/s10291-022-01355-8.
6. Bilitza D., Altadill D., Truhlik V. et al. International Reference Ionosphere 2020: Improvements, New Parameters, and Future Developments // *Advances in Space Research*. 2022. Vol. 70, Iss. 3. P. 488–508. DOI: 10.1007/s10291-022-01355-8.
7. Natras R., Soja B., Schmidt M. Ensemble Machine Learning of Random Forest, AdaBoost and XGBoost for Vertical Total Electron Content Forecasting // *Remote Sensing*. 2022. Vol. 14. P. 3547. <https://doi.org/10.3390/rs14153547>.
8. Аппалонов А. М., Масленникова Ю. С., Шерстюков О. Н. Применение нейронных сетей глубокого обучения для анализа пространственных и временных компонент разложения полного электронного содержания ионосферы // *Радиотехника*. 2025. Т. 89, № 1. С. 172–179. DOI: <https://doi.org/10.18127/j00338486-202501-16>.
9. Аппалонов А. М., Масленникова Ю. С., Шерстюков О. Н. Анализ пространственно-временных вариаций полного электронного содержания и критической частоты слоя F2 с применением нейронных сетей глубокого обучения // *Труды конференции РРВ–29*. С. 512–515. DOI: 10.26907/rwp29.2025.512-515.
10. JPL. Электронный ресурс. Официальный сайт лаборатории JPL. URL: <https://www.jpl.nasa.gov> (дата обращения: 26.07.2025).
11. Global Ionospheric Radio Observatory. Официальный сайт. URL: <https://giro.uml.edu/> (дата обращения: 26.07.2025).
12. Dominion Radio Astrophysical Observatory (DRAO): официальный сайт / National Research Council Canada. URL: <https://www.cadc-ccda.hia-ihp.nrc-cnrc.gc.ca> (дата обращения: 26.07.2025).
13. Helmholtz-Zentrum Potsdam – Deutsches GeoForschungsZentrum (GFZ). Официальный сайт / Helmholtz Association. URL: <https://www.gfz.de/> (дата обращения: 26.07.2025).
14. Аппалонов А. М., Масленникова Ю. С., Шерстюков О. Н. Разложение глобальных

карт полного электронного содержания ионосферы при помощи нейронных сетей // Материалы 22-й Международной конференции «Современные проблемы дистанционного зондирования Земли из космоса». Москва: ИКИ РАН, 2024. С. 434. DOI: 10.21046/22DZZconf-2024a.

15. *Аппалонов А. М., Масленникова Ю. С.* Краткосрочное прогнозирование полного электронного содержания ионосферы с использованием солнечных параметров методами машинного обучения // Материалы 21-й Международной конференции «Современные проблемы дистанционного зондирования Земли из космоса». Москва: ИКИ РАН, 2023. С. 299. DOI: 10.21046/21DZZconf-2023a.
16. *Masini R. P., Medeiros M. C., Mendes E. F.* Machine learning advances for time series forecasting // *Journal of Economic Surveys*. 2021. Vol. 37, No. 1. P. 76–111. DOI: 10.1111/joes.12429.

Аппалонов Артем Михайлович — аспирант Института физики Казанского (Приволжского) Федерального Университета, ул. Кремлёвская, 18, корп. 1, Казань, 420008, Россия.

E-mail: artem309_97@mail.ru

ORCID: 0000-0001-7196-9837

Масленникова Юлия Сергеевна — канд. физ.-мат. наук, доцент Казанского (Приволжского) Федерального Университета, ул. Кремлёвская, 18, корп. 1, Казань, 420008, Россия.

E-mail: yuliamsl@gmail.com

ORCID: 0000-0003-3186-7611