

Научная статья
УДК 550.385.1+550.385.4
doi:10.37614/2949-1185.2025.4.3.005

ПРОГНОЗИРОВАНИЕ РЯДОВ ИНДЕКСОВ ГЕОМАГНИТНОЙ АКТИВНОСТИ DST И AP НЕЙРОСЕТЬЮ С LSTM-СЛОЯМИ

Борис Владимирович Козелов

ФНЦ Институт прикладной физики им. А.В. Гапонова-Грехова РАН, Нижегородская обл., Россия
bob-koz@yandex.ru, <https://orcid.org/0000-0002-0217-7737>

Аннотация

Описывается реализация нейросетевого подхода с использованием слоёв LSTM (Long Shot-Term Memory) к прогнозированию рядов индексов геомагнитной активности *Dst* и *ap* на основе данных о предыдущей активности и параметрах солнечного ветра. Модель тренирована на данных базы OMNI за 2000–2023 гг. По предыстории значений *z*-компоненты межпланетного магнитного поля (*Bz* ММП), скорости солнечного ветра (*Vtot*), плотности плазмы солнечного ветра (*Np*) и индекса *Dst* за 80 часов прогнозируются следующие за ними 12 часовых значений *Dst* и *ap*. Программы работают на сайте Полярного геофизического института¹.

Ключевые слова:

индексы геомагнитной активности, прогноз, нейросети, LSTM-слой

Благодарности:

автор благодарит GSFC/SPDF OMNI Web за подготовку использованных в статье данных. Работа поддержана грантом РНФ № 23-62-10043 «Новые методы выявления и анализа закономерностей, определяющих наблюдаемую динамику сложных систем, и их применение к исследованию климатических и магнитосферных процессов».

Для цитирования:

Козелов Б. В. Прогнозирование рядов индексов геомагнитной активности DST и AP нейросетью с LSTM-слоями // Труды Кольского научного центра РАН. Серия: Естественные и гуманитарные науки. 2025. Т. 4, № 3. С. 56–65. doi:10.37614/2949-1185.2025.4.3.005.

Original article

FORECASTING SERIES OF DST AND AP GEOMAGNETIC ACTIVITY INDICES BY NEURAL NETWORK WITH LSTM LAYERS

Boris V. Kozelov

Institute of Applied Physics RAS, Nizhny Novgorod, Russia
bob-koz@yandex.ru, <https://orcid.org/0000-0002-0217-7737>

Abstract

The paper describes the implementation of a neural network approach using LSTM (Long Shot-Term Memory) layers to forecasting series of geomagnetic activity indices *Dst* and *ap* based on data on previous activity and solar wind parameters. The model is trained on the OMNI database data for 2000-2023. Based on the history of the values of the *z*-component of the interplanetary magnetic field (*Bz* IMF), solar wind speed (*Vtot*), solar wind plasma density (*Np*) and the *Dst* index for 80 hours, the following 12-hour values of *Dst* and *ap* are predicted. The programs work on the website <http://aurora.pgia.ru/AI/>.

Keywords:

geomagnetic activity indexes, forecast, neural networks, LSTM layer

Acknowledgements:

The author thanks GSFC/SPDF OMNI Web for preparing the data used in the article. The work was supported by a grant from the Russian Science Foundation and the Ministry of Education and Science of the Murmansk Region No. 22-12-20017 "Space-time structures in near-Earth space in the Arctic: from the aurora borealis through the features of plasma self-organization to the passage of radio waves".

For citation:

Kozelov B. V. Forecasting series of DST and AP geomagnetic activity indices by neural network with LSTM layers // Transactions of the Kola Science Centre of RAS. Series: Natural Sciences and Humanities. 2025. Vol. 4, no. 3. P. 56–65. doi:10.37614/2949-1185.2025.4.3.005.

¹ URL: <http://aurora.pgia.ru/AI/> (дата обращения: 15.10.2024).

Введение

В моделях ионосферы и верхней атмосферы, важных для многих прикладных вопросов, в качестве параметров используются индексы геомагнитной активности, которые получаются на основе наблюдений наземными приборами [1, 2]. Для оценки состояния моделируемых сред необходимо прогнозировать индексы геомагнитной активности. Задача прогнозирования рядов геомагнитной активности на экваториальных и средних широтах с хорошей точностью решается при наличии данных спутников о солнечном ветре, который в значительной степени определяет геомагнитную активность. Было показано, что одним из самых геоэффективных параметров солнечного ветра является его южная компонента $B_z < 0$ и связанное с ней азимутальное электрическое поле $E_y = V \cdot B_z$, где V — радиальная скорость солнечного ветра [3]. Скачки плотности плазмы в отдельных случаях также влияют на геомагнитную активность. Многие работы посвящены поиску формальной функциональной связи между параметрами солнечного ветра и индексами геомагнитной активности на основе физических представлений [4–8]. В последние годы показано, что трудно формализуемые связи могут учитываться с помощью нейросетевого подхода [9, 10], при этом особый интерес представляют рекуррентные сети, сети с памятью.

LSTM (Long Short-Term Memory, дословно — долгая краткосрочная память) — тип рекуррентной нейронной сети, способный обучаться долгосрочным зависимостям. LSTM были представлены в работе [11] и впоследствии усовершенствованы другими исследователями. Описана реализация сети со слоями LSTM для предсказания солнечной активности (числа солнечных пятен и потока радиоизлучения на волне 10,7 см) на следующий оборот Солнца [12]. В данной работе организованные таким образом слои использованы в нейронной сети для предсказания значений индексов геомагнитной активности Dst и ap на основе данных о предыдущей геомагнитной активности и параметрах солнечного ветра. Эти индексы характеризуют степень возмущённости геомагнитного поля в зоне экваториальных и средних широт соответственно. Индекс ap является производным от квазилогарифмического Kp -индекса и преобразован в численную линейную шкалу. Ранее сети со слоями LSTM успешно использовались для предсказания Dst - и Kp -индексов [13, 14]. В данной работе оперировали несколькими иными параметрами сети, в частности, использовали 80 часов предыстории не только самих индексов, но и параметров солнечного ветра, что охватывает все обсуждаемые в литературе существенные масштабы связей. Другие параметры моделей обсуждаются далее.

Цель статьи — реализовать модель прогноза геомагнитной активности (Dst - и ap -индексов) на основе данных, доступных в реальном времени.

Методы

За основу взяты данные из базы OMNI за 2000–2023 гг. с часовым разрешением: z -компонента межпланетного магнитного поля (B_z ММП), скорость солнечного ветра (V_{tot}), плотность плазмы солнечного ветра (N_p), Dst - и ap -индексы.

Из последовательности этих данных выбраны все отрезки длиной $m = 80$ ч для B_z , V_{tot} , N_p , Dst и следующие за ними 12 часовых значений Dst и ap . Отрезки, в которые попадали пробелы данных, в базе OMNI были исключены из набора. Полученный набор разбит на тренировочный и тестовый, включающие 151412 и 26505 отрезков соответственно. Из этих наборов сформированы данные для тренировки на меньшей предыстории ($m = 60, 40$ и 20 ч).

Необходимо отметить: экстремальных пиковых значений индексов Dst (< -30 нТ) и ap (> 30) относительно мало: они лежат на «хвостах» распределений. По такому ряду нейронная сеть обучается предсказывать преимущественно значения из «ядра» распределения. Однако повышенные значения геомагнитной активности представляют особый интерес для предсказания. Поэтому при тренировке сети использовали, для лучшего предсказания маловероятных значений, модификации набора выходных значений: значения Dst и ap нормировали в диапазон от 0,01 до 1,0 и возводили в некоторую степень p (см. далее табл. 1) для смещения максимума распределения. Тем самым, нормированные распределения целевых величин, на которых проводилось обучение, становились ближе к симметричному виду. На предсказанных сетью значениях делали обратное преобразование.




Рис. 1. Блок-схема использованной нейронной сети
Fig. 1. Blockdiagram of the neuralnet work used

Нейронная сеть реализована на языке Python с использованием библиотеки Keras пакета Tensor Flow. В сети использованы слои LSTM, кроме общей связи между входными и выходными данными позволяющие запоминать ближайшую предысторию в рядах данных. Общая схема блок-сети, а также составляющие сеть слои из библиотеки представлены на рис. 1.

Подаваемые на вход значения последовательно кодируются во внутреннем состоянии первой LSTM-сети, которое подаётся на вторую LSTM-сеть, и она предсказывает следующие значения, то есть сеть по m -векторам значений (Bz , $Vtot$, Np , Dst) обучалась предсказывать вектор из 12 последующих значений Dst или ap . Эти значения сравнивали с истинными, в процессе обучения минимализировали метрику «средняя абсолютная ошибка» (MAE — Mean Absolute Error).

Для обучения имеет значение, насколько полно используется информация в исходном ряду, что в данном случае характеризует параметр «потеря» (Loss — Mean Squared Error).

Из тренировочного набора 30 % выделялось для проверки (валидации) в процессе обучения. Обучение прерывалось при условии, что функция потерь (loss_val — mean squared error) на проверочном наборе не убывает на протяжении пяти эпох. Модель быстро обучается, и повышение числа эпох обучения приводит к признакам переобучения — росту MAE. Для проверки качества обучения проводили тестовое дообучение модели с уменьшением скорости обучения: оно не приводило к заметному уменьшения MAE.

Результаты и обсуждение

Таблица 1

Зависимость средней ошибки MAE на обучающей и тестовой выборке
от параметров для моделей предсказания Dst - и ap -индексов
Dependence of the average MAE error on the training and test samples on the parameters
for the Dst and ap index prediction models

Индекс	p	n	MAE обучение	MAE тест	Индекс	p	n	MAE обучение	MAE тест
Dst	4	12	11,1	9,70	ap	1/5	18	6,73	5,34
	4	18	7,75	6,81		1/5	24	6,38	5,08
	4	24	7,55	6,74		1/5	30	6,27	4,79
	4	30	8,28	7,18		1/5	36	6,23	4,79
	4	36	8,87	7,68		1/5	42	6,13	4,77
	3	24	7,75	6,82		1/5	48	6,26	4,89
	5	24	8,61	7,46		1/3	36	6,32	4,83
						1/3	42	6,13	4,88
						1/4	30	6,10	4,85
						1/4	36	6,22	4,89
						1/4	42	6,25	4,99

Примечания. 1. Параметры: n — число нейронов скрытого слоя; p — степень смещения максимума распределения прогнозируемого индекса. Длина предыстории m — 80 ч.

2. Модели с наименьшей ошибкой индексов Dst и ap выделены жирным шрифтом, субъективно лучшие модели выделены зелёным цветом.

Зависимость результатов обучения от числа нейронов скрытого слоя в LSTM-слоях и показателя степени смещения максимума распределения прогнозируемого *ap*-индекса представлена в табл. 1.

Значения MAE для истинных и предсказанных *Dst*- и *ap*-индексов из тренировочного и тестового наборов для лучших параметров p по каждому из индексов (использованы параметры модели, соответствующие подчёркнутым значениям в табл. 1) приведены на рис. 2 и 3. Несмотря на отдельные пики для больших значений, средние ошибки в целом находятся на уровне ниже 8 нТ. Интересно, что на использованных наборах данных метрика MAE всегда меньше для тестовых данных, чем для тренировочных. Видимо, в тестовом интервале оказались пики заметно меньше амплитуды, чем в тренировочном.




Рис. 2. Абсолютная ошибка предсказанных нейронной сетью и истинных значений *Dst*-индекса в ряду.

Сверху — обучающий набор, снизу — тестовый. Над графиком приведена средняя ошибка набора

Fig. 2. The absolute error of the predicted neural network and the true values of the *Dst*-index in the series.

Above is the training set; below is the test set. The average error of the set is shown above the graph

Результаты работы модели на тестовом ряду значений индексов для предсказаний на 1 ч приведены на рис. 4. На рис. 5 более детально показан короткий участок со сравнением с истинными значениями предсказаний на 1 и 12 ч. На меньшем интервале предсказания видна тенденция уточнения деталей предсказаний.

Для предсказанных временных рядов рассчитывали коэффициенты корреляции и детерминации с рядом истинных значений, их значения для лучших по метрике MAE моделей (выделены в табл. 1) приведены в табл. 2. Видно, что *Dst*-индекс хорошо предсказывается до 6 ч (коэффициент корреляции r равен 0,94, детерминация — 0,82). На больших временах корреляция и детерминация снижаются. Индекс *ap* предсказывается хуже только по солнечному ветру: r не более 0,67 и детерминация 0,44 при предсказании на 3 ч. В целом эти данные соответствуют ожиданиям.




Рис. 3. Абсолютная ошибка предсказанных нейронной сетью и истинных значений ap -индекса в ряду. Сверху — обучающий набор, снизу — тестовый. Над графиком приведена средняя ошибка набора

Fig. 3. The absolute error of the predicted neural network and the true values of the ap -index in the series. Above is the training set; below is the test set. The average error of the set is shown above the graph




Рис. 4. Сравнение истинных и прогнозируемых рядов значений индексов на тестовом наборе данных. Сверху — индекс Dst , снизу — индекс ap . Зелёная линия — наблюдения; красная — прогноз на 1 ч

Fig 4. Comparison of the true and predicted series of index values on the test data set. Above — the Dst -index; below — the ap -index. Green line — the observations, red line — the forecast for 1 hour




Рис. 5. Сравнение истинных и прогнозируемых значений индексов на фрагменте тестового набора данных.
Сверху — индекс *Dst*; снизу — индекс *ap*. Зелёная линия — наблюдения; красная — прогноз на 1 ч
Fig. 5. Comparison of true and predicted index values on a fragment of the test data set.
Above — the *Dst*-index, below — the *ap*-index. Green line — the observations, red line — the forecast for 1 hour

Таблица 2

Коэффициенты корреляции и детерминации предсказанных временных рядов индексов геомагнитной активности *Dst* и *ap* с рядом истинных значений для времён предсказания от 1 до 12 ч (использованы модели, подчёркнутые в табл. 1)
The coefficients of correlation and determination of the predicted time series of the *Dst* and *ap* geomagnetic activity indices with a number of true values for prediction times from 1 to 12 hours (the models highlighted in Table 1 are used)

Время предсказания, ч	<i>Dst</i> -индекс		<i>ap</i> -индекс	
	Коэффициент		Коэффициент	
	корреляции	детерминации	корреляции	детерминации
1	0,92	0,77	0,67	0,36
2	0,93	0,82	0,67	0,43
3	0,94	0,82	0,66	0,44
4	0,94	0,78	0,66	0,42
5	0,94	0,74	0,65	0,40
6	0,94	0,69	0,65	0,38

Окончание таблицы 2

Время предсказания, ч	<i>Dst</i> -индекс		<i>ap</i> -индекс	
	Коэффициент		Коэффициент	
	корреляции	детерминации	корреляции	детерминации
7	0,94	0,64	0,64	0,35
8	0,93	0,59	0,64	0,34
9	0,93	0,55	0,64	0,32
10	0,92	0,51	0,63	0,31
11	0,92	0,48	0,63	0,30
12	0,91	0,45	0,63	0,30

Проведённый анализ выявил необходимость уточнения требований рамочных нормативных правовых актов, принятых на федеральном уровне и регламентирующих разработку порядков в регионах. Внешним параметром, которым необходимо задать для слоёв LSTM, является n — число нейронов скрытого слоя. Это число зависит от данных и подбирается экспериментально. Для использованного набора данных установлено, что при n менее 12 качество работы сети заметно ухудшается: не удаётся добиться малого значения потерь *loss* при обучении модели, а при n более 48 чаще возникают артефакты (ложные пики) в выходной последовательности. Оказалось, что два ряда одновременно одной сетью предсказываются хуже. Для нахождения оптимального значения проводили численные эксперименты со значениями $n = 12, 18, 24, 30, 36, 42, 48$, приведёнными в табл. 1. Выбраны по две модели с наименьшей средней ошибкой предсказания для *Dst* и *ap* по MAE метрике (выделены жирным шрифтом).

Характеристика MAE не всегда совпадает с субъективной оценкой совпадения предсказанного и истинного ряда, так как для субъективной оценки более важно совпадение пиков, которые в среднее значение отклонения дают малый вклад даже в модифицированном ряду. Субъективно лучшие предсказания дают модели, для которых значения MAE подчеркнуты в табл. 1, они использованы для построения рис. 2–5.

Таблица 3

Зависимость средней ошибки MAE на обучающей и тестовой выборке
от длины предыстории для моделей предсказания *Dst*- и *ap*-индексов
Dependence of the average MAE error on the training and test samples on the length
of the background for *Dst* and *ap* index prediction models

Индекс	m	p	n	MAE обучение	MAE тест	Индекс	m	p	n	MAE обучение	MAE тест
<i>Dst</i>	80	4	24	7,55	6,74	<i>ap</i>	80	1/5	36	6,31	4,88
	60	4	24	8,99	7,81		60	1/5	36	6,32	4,97
	40	4	24	8,45	7,40		40	1/5	36	6,16	4,88
	20	4	24	9,32	8,13		20	1/5	36	6,19	4,74

Примечание. N — число нейронов скрытого слоя; p — степень смещения максимума распределения прогнозируемого индекса; m — длина предыстории.

В настоящей работе для предсказания использовали ряды данных 80 ч предыстории, согласно взятым для прогноза данным сайта¹. К примеру, в работах [9, 10] ряды были более короткими, с предысторией 8 ч, но авторами заранее были отобраны только события изолированных бурь. Мы провели тестирование моделей на более коротких рядах, результаты показаны в табл. 3. Видно,

¹ URL: https://lasp.colorado.edu/space_weather/dsttemerin/ (дата обращения: 15.11.2024).

что использование длительной предыстории для Dst позволяет несколько уменьшить MAE предсказания. Для ap такой зависимости нет, ошибка MAE даже несколько снижается с уменьшением длины предыстории, хотя не столь значительно, чтобы делать выводы. Субъективно же предсказание с длительной предысторией лучше описывает флуктуации ap -индекса порядка нескольких десятков часов.

Известно, что включение в прогностическую модель дополнительной эмпирической информации улучшает прогноз. Так, в работе [13] для предсказания значений Dst -индекса от 1 до 6 ч по параметрам солнечного ветра использована предыстория на 6 ч, однако для лучшего описания пиковых значений добавлена дополнительная ветвь в нейросети для значений $Dst > 6$. Скрытый слой состоял из 20 нейронов. Также улучшения прогноза авторы добивались включением дополнительной информации — оценки поглощения из данных GPS.

Комбинированная модель с использованием слоя LSTM выстроена в работе [14] для предсказания Kp -индекса на 3 ч вперёд по параметрам солнечного ветра и межпланетного магнитного поля по предыстории за 6 ч. В модели строятся отдельные ветви для условий магнитной бури и при её отсутствии. Использование дополнительных ветвей приводит к неплохому прогнозу, даже при небольшой предыстории.

Заключение

Описана реализация нейросетевого подхода с использованием слоев LSTM (Long Shot-Term Memory) к прогнозированию рядов индексов геомагнитной активности Dst и ap . Использованы данные из базы OMNI за 2000–2023 гг. с часовым разрешением. По предыстории значений параметров солнечного ветра (Bz ММП, скорость V_{tot} , плотность Np) и индекса Dst за 80 ч спрогнозированы следующие за ними 12 часовых значений Dst и ap . Исследованы зависимости «средней абсолютной ошибки» предсказания модели от числа нейронов в скрытых слоях LSTM слоёв и длины предыстории в данных. Для моделирования оптимально использовать разные модели при числе нейронов скрытого слоя 18–24 (для Dst) и 30–42 (для ap). Длина использованной предыстории в данных обуславливается рядом значений, которые предполагается использовать для прогноза. Сокращение предыстории ухудшает прогноз.

Программы работают на сайте ПГИ¹. Для оперативного прогноза данные по Bz ММП, V_{tot} и Np в виде картинок загружаются с сайта² и оцифровываются. Данные индекса Dst геомагнитной активности заимствованы с сайта World Data Center for Geomagnetism (Kyoto)³ [15]. Текущие значения ap доступны на сайте⁴, прогноз обновляется каждые 3 ч.

Для лучшего предсказания маловероятных экстремальных значений предложено модифицировать набор выходных значений показательной функцией к более симметричному виду. Для дальнейшего улучшения прогноза в последующих работах в сеть можно ввести дополнительные ветви, использующие добавочную эмпирическую информацию.

Список источников

1. Шубин В. Н., Деминов М. Г. Глобальная динамическая модель критической частоты F₂-слоя ионосферы // Геомагнетизм и аэрономия. 2019. Т. 59, № 4. С. 461–473.
2. Vorobjev V. G., Yagodka O. I., Katkalov Y. Auroral Precipitation Model and its applications to ionospheric and magnetospheric studies // J. Atm. S-Terr. Phys. 2013. Vol. 102 (9). P. 157–171.
3. Burton R. K., McPherron R. L., Russel C. J. An empirical relationship between interplanetary conditions and Dst // Geophys. Res. 1975. Vol. 80. P. 4204–4214.
4. Дремухина Л. А., Лодкина И. Г., Ермолаев Ю. Связь параметров солнечного ветра разных типов с индексами геомагнитной активности // Космические исследования. 2018. Т. 56, № 6. С. 410–419.

¹ URL: http://aurora.pgia.ru/AI/?id=dst_pred (дата обращения: 15.10.2024).

² URL: https://lasp.colorado.edu/space_weather/dsttemerin/ (дата обращения: 15.10.2024).

³ URL: <http://wdc.kugi.kyoto-u.ac.jp> (дата обращения: 15.10.2024).

⁴ URL: https://www-app3.gfz-potsdam.de/kp_index/Kp_ap_nowcast.txt (дата обращения: 15.10.2024).

5. Kan J. R., Lee L. C. Energy coupling function and solar wind-magnetosphere dynamo // *Geophys. Res. Lett.* 1979. Vol. 6. P. 577–580.
6. A nearly universal solar wind-magnetosphere coupling function inferred from 10 magnetospheric state variables / P. T. Newell [et al.] // *J. Geophys. Res.* 2007. Vol. 112. P. A01206. doi:10.1029/2006JA012015.
7. Borovsky J. E., Birn J. The solar wind electric field does not control the dayside reconnection rate // *J. Geophys. Res. Space Physics*. 2014. Vol. 119. P. 753–760. doi:10.1002/2013JA019193.
8. Borovsky J. E. Canonical correlation analysis of the combined solar-wind and geomagnetic-index data sets // *J. Geophys. Res.* 2014. Vol. 119. P. 5364–5381. doi:10.1002/2013JA019607.
9. Бархатов Н. А., Ревунов С. Е. Искусственные нейронные сети в задачах солнечно-земной физики. Н. Новгород: Поволжье, 2010. 407 с.
10. Neural network classification of substorm geomagnetic activity caused by solar wind magnetic clouds / N. A. Barkhatov [et al.] // *J. Atmosph. and Solar-Terr. Phys.* 2020. Vol. 205. P. 105301.
11. Hochreiter S., Schmidhuber J. Long short-term memory // *Neural computation*. 1997. Vol. 9 (8). P. 1735–1780.
12. Козелов Б. В. Предсказание временных рядов солнечной активности с помощью искусственной нейронной сети LSTM // *Труды Кольского НЦ РАН. Серия Естественные и гуманитарные науки*. 2023. Т. 2, № 2. С. 19–24. doi:10.37614/2949-1185.2023.2.2.003.
13. Multiple-hour ahead forecast of the Dst index using a combination of long short-term memory neural network and Gaussian process / M. A. Gruet [et al.] // *Space Weather*. 2018. Vol. 16. P. 1882–1896. <https://doi.org/10.1029/2018SW001898>.
14. Geomagnetic index Kp forecasting with LSTM / Y. Tan [et al.] // *Space Weather*. 2018. Vol. 1. P. 406–416. <https://doi.org/10.1002/2017SW001764>.

References

1. Shubin V. N., Deminov M. G. Global'naya dinamicheskaya model' kriticheskoy chastoty F₂-sloya ionosfery [Global dynamic model of the critical frequency of the F₂ layer of the ionosphere]. *Geomagnetizm i aeronomiya* [Geomagnetism and Aeronomy], 2019, Vol. 59, no. 4, pp. 461–473. (In Russ.).
2. Vorobjev V. G., Yagodkina O. I., Katkalov Y. Auroral Precipitation Model and its applications to ionospheric and magnetospheric studies. *J. Atm. S-Terr. Phys.*, 2013, Vol. 102 (9), pp. 157–171.
3. Burton R. K., McPherron R. L., Russel C. J. An empirical relationship between interplanetary conditions and Dst. *Geophys. Res.*, 1975, Vol. 80, pp. 4204–4214.
4. Dremuhina L. A., Lodkina I. G., Ermolaev Yu. Svyaz' parametrov solnechnogo vetra raznyh tipov s indeksami geomagnitnoj aktivnosti [Relationship of solar wind parameters of different types with geomagnetic activity indices]. *Kosmicheskie issledovaniya* [Space Research], 2018, Vol. 56, no. 6, pp. 410–419. (In Russ.).
5. Kan J. R., Lee L. C. Energy coupling function and solar wind-magnetosphere dynamo. *Geophys. Res. Lett.*, 1979, Vol. 6, pp. 577–580.
6. Newell P. T., Sotirelis T., Liou K., Meng C. I., Rich F. A nearly universal solar wind-magnetosphere coupling function inferred from 10 magnetospheric state variables. *J. Geophys. Res.*, 2007, Vol. 112, pp. A01206. doi:10.1029/2006JA012015.
7. Borovsky J. E., Birn J. The solar wind electric field does not control the dayside reconnection rate. *J. Geophys. Res. Space Physics*, 2014, Vol. 119, pp. 753–760. doi:10.1002/2013JA019193.
8. Borovsky J. E. Canonical correlation analysis of the combined solar-wind and geomagnetic-index data sets. *J. Geophys. Res.*, 2014, Vol. 119, pp. 5364–5381. doi:10.1002/2013JA019607.
9. Barkhatov N. A., Revunov S. E. *Iskusstvennye nejronnye seti v zadachah solnechno-zemnoj fiziki* [Artificial neural networks in solar-terrestrial physics problems]. N. Novgorod, Povolzh'e, 2010, 407 p.
10. Barkhatov N. A., Vorobjev V. G., Revunov S. E., Barkhatova O. M., Revunova E. A., Yagodkina O. I. Neural network classification of substorm geomagnetic activity caused by solar wind magnetic clouds. *J. Atmospheric and Solar-Terrestrial Physics*, 2020, Vol. 205 (2), pp. 105301.
11. Hochreiter S., Schmidhuber J. Long short-term memory. *Neural computation*, 1997, Vol. 9 (8), pp. 1735–1780.
12. Kozelov B. V. Predskazanie vremennyh ryadov solnechnoj aktivnosti s pomoshch'yu iskusstvennoj nejronnoj seti LSTM [Prediction of solar activity time series using LSTM artificial neural network]. *Trudy Kolskogo nauchnogo centra RAN* [Transactions of the Kola Science Centre of RAS. Series: Natural Sciences and Humanities], 2023, Vol. 2, no. 2, pp. 19–24. doi:10.37614/2949-1185.2023.2.2.003 (In Russ.).

13. Gruet M. A., Chandorkar M., Sicard A., Camporeale E. Multiple-hour ahead forecast of the Dst index using a combination of long short-term memory neural network and Gaussian process. *Space Weather*, 2018, Vol. 16, pp. 1882–1896. <https://doi.org/10.1029/2018SW001898>.
14. Tan Y., Hu Q., Wang Z., Zhong Q. Geomagnetic index Kp forecasting with LSTM. *Space Weather.*, 2018, Vol. 1, pp. 406–416. <https://doi.org/10.1002/2017SW001764>.

Информация об авторе

Б. В. Козелов — доктор физико-математических наук, ведущий научный сотрудник

Information about the author

B. V. Kozelov — Dr. Sc. (Phys.&Math.), Leading Researcher

Статья поступила в редакцию 15.11.2024; одобрена после рецензирования 25.04.2025; принята к публикации 29.08.2025.
The article was submitted 15.11.2024; approved after reviewing 25.04.2025; accepted for publication 29.08.2025.