

ИССЛЕДОВАНИЕ И РАЗРАБОТКА МЕТОДОВ ПРОГНОЗИРОВАНИЯ СОЛНЕЧНОЙ АКТИВНОСТИ С ПРИМЕНЕНИЕМ НЕЙРОСЕТЕВЫХ МЕТОДОВ

Ф.С. Карев¹, К.В. Галанов¹

¹Самарский университет, г. Самара
e-mail: fr.frederiko.456.kar@gmail.com, galanov.kv@ssau.ru

Аннотация

В работе исследуется применение нейронных сетей для прогнозирования солнечной активности, на ряду солнечных пятен. Рассматривались модели GRU и LSTM. В результате сравнительных экспериментов был выявлен сдвиг в графиках результата, вызванный особенностями моделей и видом получаемых данных. Найден способ уменьшения сдвига, путём перехода к прогнозированию приращений временного ряда и последующему восстановлению абсолютных значений и увеличением времени обучения для модели.

Ключевые слова: моделирование, солнечная активность, солнечные вспышки, солнечные пятна, искусственные нейронные сети.

Введение

Солнечная активность оказывает значительное влияние на космическую погоду и технологическую инфраструктуру Земли. Одним из ключевых индикаторов активности является число солнечных пятен (Sunspot Number, SN), представляющее собой временной ряд.

Для решения задачи используются рекуррентные нейронные сети, такие как LSTM и GRU, так как они демонстрируют высокую эффективность при работе с временными рядами благодаря способности учитывать временные зависимости в данных [1].

В данной работе рассматривается задача прогнозирования суточного числа солнечных пятен. Пусть задан временной ряд:

$$y_t, t = 1, 2, \dots, N,$$

где y_t – число солнечных пятен в момент времени t .

Качество прогнозирования оценивается с использованием метрик средней абсолютной ошибки (MAE) $MAE = \frac{1}{n} \sum_{i=1}^n |Y_i - \hat{Y}_i|$ и среднеквадратичной ошибки (MSE) $MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2$, а также путём сравнения с наивным методом прогнозирования.

Цель данной работы – исследовать применимость рекуррентных нейронных сетей, такие как GRU и LSTM для прогнозирования солнечной активности, а также анализ факторов, влияющих на точность прогноза.

Научная новизна работы – исследование временного сдвига при GRU-прогнозировании солнечных пятен и оценка дифференцирования ряда для устранения этого эффекта.

1. Описание эксперимента и модели

Выбранные модели обучались по данным с 1.01.1818 по 30.04.2025 предсказывать значения вперёд на 1 день [2]. Шаг дискретизации в данном наборе данных измеряется в 1 день.

Подготовка данных включала удаление пропусков и нормализацию методом MinMaxScaler в диапазоне от 0 до 1.

Размер батча 64 выбран эмпирически как компромисс между скоростью обучения и стабильностью сходимости [3].

В первом эксперименте был выбран размер окна, равный 30 суткам. Данный выбор обусловлен тем, что указанный интервал позволяет быстро обучить обе модели, и выбрать лучшую из них. Входные данные для модели имеют размерность:

$$(window_size \times 1), \quad (1)$$

где, *window_size* – длина временного окна (30 или 60), а единица соответствует одному признаку – числу солнечных пятен.

Архитектуры LSTM и GRU моделей: размерность входного слоя – *window_size* * 1; количество нейронов – 64; Dense – 1 нейрон; Dropout – нет. Обучение моделей проводилось с использованием оптимизатора Adam. Количество эпох обучения было равно 10 для более быстрого обучения моделей. 80% данных были использованы для обучения, остальные 20% – на тестирование.

Процесс работы:

- На вход подаётся последовательность из 30 нормализованных значений количества солнечных пятен (SN).
- LSTM и GRU обрабатывает эти данные, запоминая тренды, циклы и изменения.
- Dense преобразует результат в одно значение – прогноз SN на следующий день.
- Во время обучения сеть сверяет предсказание с реальным значением и обновляет веса (градиентный спуск).

2. Результаты

Таблица 1 – Результаты обучения моделей LSTM и GRU

Модель	Время обучения	MAE	MSE
LSTM	195	12,29	273,67
GRU	270	11,46	235,32

Сравнительный анализ показал, что модель GRU демонстрирует более высокое качество прогнозирования по сравнению с LSTM по метрике MAE на $\approx 6,75\%$, а по метрике MSE $\approx 14,01\%$. Сравнение графиков моделей показало запаздывание прогноза на 1–2 дня (лаг максимальной корреляции рядов), особенно заметное в областях экстремумов.




Рисунок 1 – График истинных значений и предсказаний LSTM и GRU¹

¹ Синяя линия – Истинное значение
Оранжевая линия – LSTM
Зеленая линия – GRU

3. Исследование методов уменьшение структурного сдвига

Для устранения временного сдвига можно использовать дифференцирование ряда, перейдя от абсолютных значений к их изменениям. Такое представление снижает инерционность модели и повышает её чувствительность к локальным колебаниям, что уменьшает запаздывание прогноза.

В рамках работы рассматривались разности первого порядка: $\Delta y_k = y_k - y_{k-1}$. При этом модель обучалась прогнозировать приращения $\Delta \hat{y}_{k+1}$ вместо абсолютных значений. Такой подход устраняет возможность использования стратегии копирования ($\hat{y}_{k+1} \approx y_k$) и вынуждает модель выявлять закономерности в динамике изменений временного ряда [5, 6].

В рамках данного эксперимента рассматривался одноступенчатый прогноз, при котором предсказывается значение $\Delta \hat{y}_{t+1}$. Для получения прогноза в исходном масштабе выполнялось интегрирование: $y_{pred(k+1)} = y_{fact(k)} + \Delta y_{pred(k+1)}$. В качестве базовой модели использовался наивный прогноз, описываемый выражением: $y(k+1) = y(k)$ [7].

Размер входного окна был установлен на значении 60 суток, что позволяет анализировать динамику двух полных циклов вращения Солнца вокруг своей оси. Обучение проводилось в течение 20 эпох с размером батча 64. Результаты ошибки MSE GRU = 225,41, наивного прогноза = 354,78. Сравнительный анализ показал, что модель GRU превосходит наивный прогноз по метрике MSE (225,41 против 354,78). Относительное улучшение составило около 36,5%.

Анализ графика (рисунок 2) показывает, что модель GRU точнее моделирует временной ряд: она лучше улавливает экстремумы и фазы активности без завышения значений на стабильных участках. Это говорит о её способности находить скрытые закономерности, а не просто дублировать текущие данные.



Рисунок 2 – Интегрированный прогноза GRU и истинные значения

Заключение

В рамках данной работы был проведён сравнительный анализ моделей рекуррентных нейронных сетей LSTM и GRU для задачи прогнозирования солнечной активности на основе временного ряда суточного числа солнечных пятен.

На первом этапе исследования установлено, что модель GRU обеспечивает более высокую точность по сравнению с LSTM (MAE: 12,29 → 11,46; MSE: 273,67 → 235,32). При этом время обучения модели GRU оказалось выше (270 секунд против 195 секунд). Несмотря на это, улучшение качества прогноза позволило выбрать модель GRU в качестве основной для дальнейших исследований.

На втором этапе был выявлен эффект временного сдвига, проявляющийся в запаздывании прогноза относительно фактических значений, особенно в областях локальных экстремумов. Показано, что он связан с инерционностью временного ряда и сглаживающим характером оптимизации модели.

На третьем этапе для уменьшения эффекта временного сдвига применено дифференцирование временного ряда. Переход к прогнозированию приращений позволил снизить инерционность и устранить стратегию копирования, что привело к улучшению качества прогноза на 36,5% в сравнении с наивным методом.

Таким образом, сочетание GRU и дифференцирования ряда повышает точность краткосрочного прогноза и уменьшает временной сдвиг. Полученные результаты масштабируются и на другие задачи прогнозирования временных рядов.

Перспективы дальнейших исследований включают переход к многодневному прогнозированию, использование экзогенных признаков, применение альтернативных архитектур (TCN, Transformer) и развитие мультимодальных моделей.

Список использованных источников

1. Detection of bars in galaxies using a deep convolutional neural network / S. Abraham [et al.] // Monthly Notices of the Royal Astronomical Society. – 2018. – V. 477, № 1. – P. 894–903. – URL: <https://academic.oup.com/mnras/article/477/1/894/4925012>.
2. Sunspots dataset. – URL: <https://short-url.cc/1y9HU>.
3. Accurate, large minibatch sgd: Training imagenet in 1 hour / P. Goyal [et al.] // arXiv preprint. – 2017. – URL: <https://arxiv.org/abs/1706.02677>
4. A comprehensive overview and comparative analysis on deep learning models: CNN, RNN, LSTM, GRU / F. M. Shiri [et al.] // arXiv preprint. – 2023. – URL: <https://short-url.cc/1y9I6>.
5. Временные ряды. Прогнозирование и модели. Библиотеки Python. – URL: <https://short-url.cc/1sEQz>.
6. Прикладной статистический анализ данных. 9. Анализ временных рядов, часть первая. – URL: <https://short-url.cc/1y9Hx>.
7. Козелов, Б.В. Предсказание временных рядов солнечной активности с помощью искусственной нейронной сети LSTM / Б.В. Козелов // Труды Кольского научного центра РАН. Серия: Естественные и гуманитарные науки. – 2023. – № 2. – URL: <https://short-url.cc/1y9Ap>.

RESEARCH AND DEVELOPMENT OF SOLAR ACTIVITY FORECASTING METHODS USING NEURAL NETWORK METHODS

F.S. Karev¹, K.V. Galanov¹

¹*Samara University, Samara*

e-mail: fr.frederiko.456.kar@gmail.com, galanov.kv@ssau.ru

Abstract

This paper explores the use of neural networks for forecasting solar activity in sunspot series. GRU and LSTM models are considered. Comparative experiments revealed the results in graphical output, the associated model features, and the type of data obtained. A principal shift method was identified, along with a transition path to forecasting time series increments and subsequent restoration of absolute results and initial model training.

Keywords: modeling, solar activity, solar flares, sunspots, artificial neural networks.