

## НЕЙРОСЕТЬ ДЛЯ ПРОГНОЗИРОВАНИЯ ВРАЩЕНИЯ ЗЕМЛИ

А.П. Горбачевская

gorbachevskayaap@student.bmstu.ru

*МГТУ им. Н.Э. Баумана, Москва, Российская Федерация*

Выполнено сравнение прогнозов Международной службы вращения Земли (IERS) с прогнозами, полученными с помощью нейронной сети. Для этого использованы данные о положении полюса, полученные из источника IERS. Результаты прогнозов сравнивали при использовании различных архитектур рекуррентной нейронной сети с целью оценки точности и эффективности нейросетевого подхода. Особое внимание было уделено анализу различий между прогнозами IERS и прогнозам нейросети, а также выявлению возможных преимуществ нейронной сети в данной области. Сделаны выводы о перспективах использования нейросети для разработки более точных моделей ориентации Земли.

**Ключевые слова:** нейронная сеть, нейросетевой подход, прогнозирование, вращение Земли, модели ориентации Земли, Международная служба вращения Земли (IERS), рекуррентные нейронные сети

**Введение.** Изменения в положении полюса Земли имеют значение для понимания геодинамических процессов, таких как изменение климата, сезонные колебания и даже землетрясения. Поэтому точное прогнозирование вращения Земли является ключевым аспектом мониторинга и прогнозирования геофизических явлений [1–6].

**Роль IERS в прогнозировании вращения Земли.** IERS (International Earth Rotation and Reference Systems Service) — это международная служба по вращению Земли и системам отсчета. Она занимается наблюдением и изучением изменений во вращении Земли, определением систем отсчета времени и координат, а также разработкой стандартов и моделей для использования в научных и технических приложениях. IERS является ключевой международной организацией, которая обеспечивает точные и надежные данные о вращении Земли и времени для геодезии, астрономии, навигации, геофизики и других областей.

Одной из задач IERS является прогнозирование изменений во вращении Земли, времени и пространстве. Вот некоторые методы, которые используются для прогноза:

1) *астрономические наблюдения:* IERS использует данные наблюдений астрономических объектов, таких как звезды, планеты и космические объекты, для определения параметров вращения Земли и времени;

2) *глобальные навигационные спутниковые системы (GNSS)*: IERS использует данные от спутниковых систем, таких как GPS, ГЛОНАСС и Galileo, для мониторинга движения Земли и ее вращения;

3) *гравиметрические и геодезические измерения*: IERS использует данные измерений гравитационного поля Земли и ее геодезических параметров для прогнозирования изменений в ее вращении и ориентации;

4) *моделирование и анализ данных*: IERS разрабатывает математические модели, которые учитывают различные факторы, влияющие на вращение Земли, такие как гравитационное воздействие Луны и Солнца, атмосферные условия и внутренние процессы в Земле.

Таким образом, IERS применяет комплексный подход, включающий в себя астрономические наблюдения, данные навигационных систем и моделирование гравитационных воздействий для составления прогнозов и обеспечения точности глобальных систем координат и времени.

На официальном веб-сайте IERS доступны данные о прогнозах изменений во вращении Земли, а также исторические данные о движении Земли начиная с 1973 г. [7]. Используя эти достоверные значения, можно разработать нейронную сеть, которая будет способна автоматически прогнозировать последующие изменения во вращении Земли. Однако прежде чем приступить к рассмотрению данной задачи, необходимо проанализировать понятие нейронной сети и ее функциональные принципы.

**Нейронные сети: архитектура и обучение.** Нейронная сеть представляет собой компьютерную модель, которая имитирует функционирование человеческого мозга. Она состоит из множества взаимосвязанных искусственных нейронов, способных обрабатывать входные данные, выполнять вычисления и генерировать выходные значения. Нейронная сеть обладает способностью к обучению и в определенных случаях может обучаться самостоятельно.

Процесс обучения нейронной сети предусматривает несколько этапов, включая подготовку набора данных для обучения, выбор подходящей архитектуры нейросети, передачу обучающих данных через сеть, вычисление ошибки между предсказанными и фактическими значениями и оценку производительности нейронной сети.

Нейросети могут быть реализованы на таких языках, как Python, C++, Java, JavaScript, и др. Однако Python остается одним из самых популярных языков для разработки нейронных сетей благодаря обширному набору библиотек для машинного обучения, таких как TensorFlow, PyTorch, Keras, и др., что упрощает разработку нейронных сетей.

Существует различные типы нейронных сетей, различающиеся по архитектуре, областям применения и другим характеристикам. Среди них наиболее

лее распространены нейронные сети прямого распространения (The Feed-Forward Neural Network — FFNN), сверточные нейронные сети (Convolutional Neural Networks — CNN) и рекуррентные нейронные сети (Recurrent Neural Networks — RNN). Рассмотрим подробнее последние.

Рекуррентные нейронные сети (RNN) представляют собой класс нейронных сетей, способных обрабатывать последовательные данные, такие как текст, звук или временные ряды. Они обладают способностью запоминать предыдущие состояния и использовать их для обработки последующих входных данных.

Обучение RNN подобно обучению обычной нейронной сети, однако существуют определенные ограничения, такие как проблема исчезающего градиента и сложность обучения на длинных последовательностях. Это привело к разработке более продвинутых архитектур, которые помогают решить эти проблемы. Среди них наиболее популярны архитектуры длительной кратковременной памяти (Long Short-Term Memory — LSTM) и закрытого рекуррентного модуля (Gated Recurrent Unit — GRU).

LSTM представляет собой модификацию RNN, которая включает дополнительные механизмы для контроля потока информации внутри ячейки памяти. Это позволяет LSTM более эффективно улавливать долгосрочные зависимости в данных. GRU, в свою очередь, является упрощенной версией LSTM, обладающей механизмами для контроля потока информации, но с меньшим количеством параметров [8, 9].

**Создание нейросети.** Данные, взятые из источника IERS (рис. 1), масштабируются с использованием метода MinMaxScaler для подготовки к обучению модели. Затем создается последовательность данных для обучения нейронной сети. Эта последовательность представляет собой входные и выходные значения, необходимые для прогнозирования.

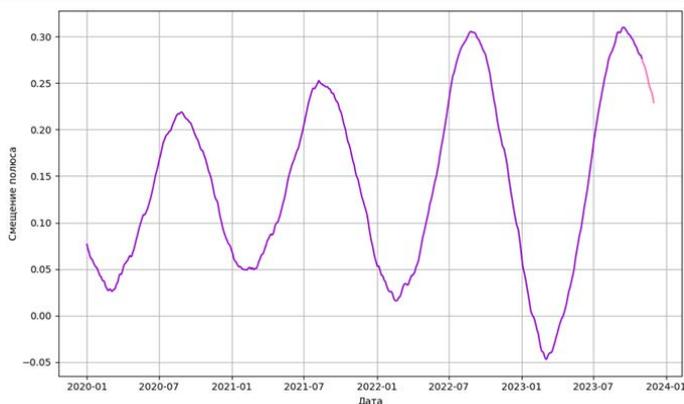
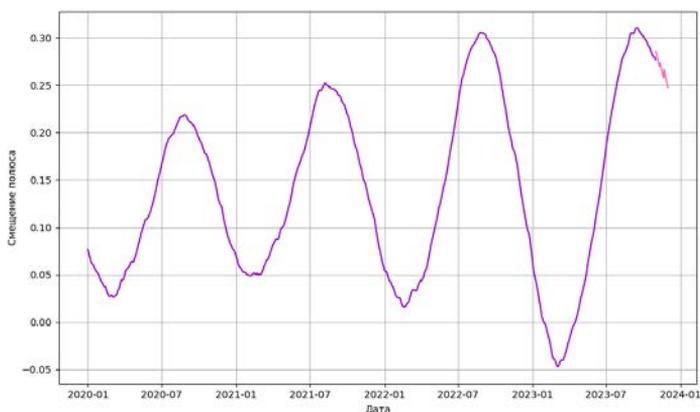


Рис. 1. График значений из источника IERS

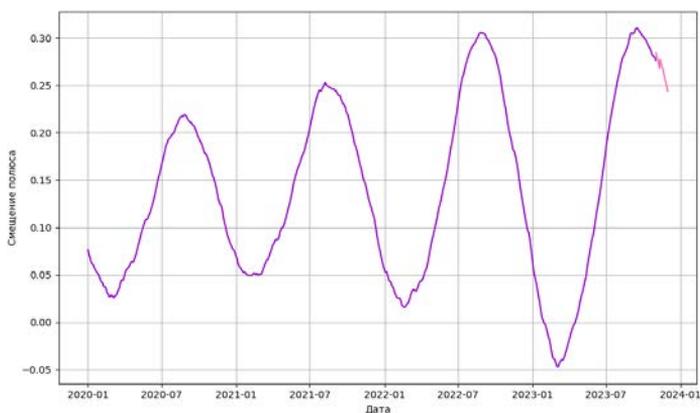
Розовым на рис.1 показаны значения, которые дальше будут прогнозироваться нейронной сетью. По оси ординат отложены значения смещение полюса в радианах.

Нейросеть создается с применением библиотеки TensorFlow. Она включает в себя два слоя LSTM и один плотный слой. После этого модель компилируется с использованием оптимизатора adam и функций потерь mse и mae (рис. 2).

Для сравнения производительности модели была разработана и обучена нейронная сеть с использованием модели GRU (Gated Recurrent Unit), которая также включает в себя два слоя GRU и один плотный слой (рис. 3).



**Рис. 2.** График прогноза, полученный с помощью LSTM



**Рис. 3.** График прогноза, полученный с помощью GRU

Для компиляции модели был использован оптимизатор adam с функциями потерь mse и mae. После этого осуществилось обучение на имеющихся данных. На основании проведенного анализа был сделан прогноз на 30 дней. Более наглядно сравнить результаты можно с помощью рис. 4.



Рис. 4. График, полученный из источника IERS, и с использованием LSTM и GRU

**Сравнение результатов.** Для оценки производительности моделей используются различные метрики, включая среднеквадратичную ошибку (mse) и среднюю абсолютную ошибку (mae).

Метрика MSE (Mean Squared Error) — одна из наиболее распространенных метрик для оценки качества моделей машинного обучения, особенно в задачах регрессии (рис. 5, 6).

Среднеквадратичная ошибка (MSE): 1.7168116755783558e-05

Рис. 5. Ошибка MSE, полученная на модели LSTM

Среднеквадратичная ошибка (MSE): 1.8306054698769003e-05

Рис. 6. Ошибка MSE, полученная на модели GRU

Формула для вычисления среднеквадратичной ошибки выглядит следующим образом:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2,$$

где  $n$  — количество наблюдений;  $y_i$  — фактическое значение;  $\hat{y}_i$  — предсказанное значение.

Чем меньше значение, тем лучше модель предсказывает данные.

Метрика MAE (Mean Absolute Error) — метрика оценки качества модели, которая измеряет среднее абсолютное отклонение между прогнозами модели и фактическими значениями [10] (рис. 7, 8).

Средняя абсолютная ошибка (MAE): 0.0027345616836100817

Рис. 7. Ошибка MAE, полученная на модели LSTM

Средняя абсолютная ошибка (MAE): 0.0032503337133675814

Рис. 8. Ошибка MAE, полученная на модели LSTM

Формула для расчета средней абсолютной ошибки имеет следующий вид:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|.$$

Здесь  $n$  — количество наблюдений;  $y_i$  — фактическое значение;  $\hat{y}_i$  — предсказанное значение.

На основании полученных результатов можно утверждать, что модель LSTM демонстрирует более низкое значение по сравнению с моделью GRU. Это свидетельствует о более точном прогнозировании временных рядов с использованием модели LSTM по сравнению с моделью GRU.

**Заключение.** Результаты сравнения прогнозов IERS с прогнозами, полученными с использованием нейронной сети, позволяют сделать вывод о точности и эффективности прогнозов. Нейросеть продемонстрировала способность предсказывать изменения положения Земли с высокой точностью и в достаточной степени предсказывать будущие значения.

Таким образом, использование нейронной сети для прогнозирования вращения Земли может представлять собой перспективный подход, дополняющий и улучшающий существующие методы прогнозирования, такие как

прогнозы IERS. Дальнейшие исследования в этой области могут привести к разработке более точных и надежных моделей прогнозирования изменений в положении полюса Земли.

## Литература

- [1] Манк У., Макдональд Г. *Вращение Земли*. 1964, Москва, Мир, 384 с.
- [2] Мориц Г., Мюллер А. *Вращение Земли: теория и наблюдения*. Киев, Наукова думка, 1992.
- [3] Марков Ю.Г., Перепелкин В. В., Сеницын И.Н., Семендяев Н.Н. Информационные модели неравномерности вращения Земли. *Информ. и ее примен.*, 2011, № 5, с. 17–35.
- [4] Яцкив Я.С., Миронов Н.Т., Корсунь А.А., Тарадий В.К. *Движение полюсов и неравномерность вращения Земли*. Москва, ВИНТИ, 1976, т. 12, ч. 1, 2.
- [5] Акуленко Л.Д., Марков Ю.Г., Перепёлкин В.В. Неравномерности вращения Земли. *ДАН*, 2007, т. 417, № 4, с. 483–488.
- [6] Акуленко Л.Д., Марков Ю.Г., Перепёлкин В.В., Рыхлова Л.В. Внутригодовые неравномерности вращения Земли. *Астрон. журн.*, 2008, т. 85, № 7, с. 657–664.
- [7] IERS. Available at: <https://www.iers.org/> (accessed November 25, 2023).
- [8] Rojas R. *Neural Networks: A Systematic Introduction*. Heidelberg, Springer Berlin, 1996, 509 p.
- [9] Чару А. *Нейронные сети и глубокое обучение*. Санкт-Петербург, Диалектика, 2020, 752 с.
- [10] Кильдишев Г.С., Френкель А.А. *Анализ временных рядов и прогнозирование*. Москва, Статистика, 1973.

**Поступила в редакцию 25.04.2024**

**Горбачевская Анастасия Павловна** — студентка кафедры «Высшая математика», МГТУ им. Н.Э. Баумана, Москва, Российская Федерация.

**Научный руководитель** — Баркин Михаил Юрьевич, кандидат физико-математических наук, доцент кафедры «Теоретическая механика», МГТУ им. Н.Э. Баумана, Москва, Российская Федерация.

**Ссылку на эту статью просим оформлять следующим образом:**

Горбачевская А.П. Нейросеть для прогнозирования вращения Земли. *Политехнический молодежный журнал*, 2024, № 03 (92). URL: [https://ptsj.bmstu.ru/catalog/phys/astr\\_ph/975.html](https://ptsj.bmstu.ru/catalog/phys/astr_ph/975.html)

## NEURAL NETWORK IN PREDICTING THE EARTH ROTATION

**A.P. Gorbachevskay**

gorbachevskayaap@student.bmstu.ru

*Bauman Moscow State Technical University, Moscow, Russian Federation*

The paper compares the International Earth Rotation Service (IERS) forecast with the forecasts obtained using a neural network. For this purpose, the pole position data obtained from the IERS source are used. The forecast results are being compared using the different recurrent neural network architectures in order to assess accuracy and efficiency of the neural network approach. The paper pays particular attention to analyzing differences between the IERS forecasts and the neural network forecasts, as well as to identifying the neural network probable advantages in this area. The paper concludes on the prospects for introducing a neural network in developing the more accurate Earth orientation models.

**Keywords:** neural network, neural network approach, forecasting, Earth rotation, Earth orientation models, International Earth Rotation Service (IERS), recurrent neural networks

---

***Received 25.04.2024***

**Gorbachevskaya A.P.** — Student, Department of Higher Mathematics, Bauman Moscow State Technical University, Moscow, Russian Federation.

**Scientific advisor** — Barkin M.Yu., Ph. D. (Phys.-Math.), Associate Professor, Department of Theoretical Mechanics, Bauman Moscow State Technical University, Moscow, Russian Federation.

**Please cite this article in English as:**

Gorbachevskaya A.P. Neural network in predicting the Earth rotation. *Politekhnicheskiy molodezhnyy zhurnal*, 2024, no. 03 (92). (In Russ.). URL: [https://ptsj.bmstu.ru/catalog/phys/astr\\_ph/975.html](https://ptsj.bmstu.ru/catalog/phys/astr_ph/975.html)