

## РАЗРАБОТКА МОДЕЛИ И ПРОГРАММЫ ПРОГНОЗА ГЕОМАГНИТНОЙ АКТИВНОСТИ НА ОСНОВЕ ИНДЕКСА Z

*Бекпулатов Ж.Х., студент магистратуры.  
Ташкентский университет информационных  
технологий имени Мухаммада ал-Хоразмий.*

*E-mail: bekpulatovjavlan@gmail.com;  
моб. тел.: +998 91 916-76-56*

### Аннотация

В статье рассматривается задача прогнозирования геомагнитной активности на основе индекса Z. Показано, что традиционные регрессионные методы обладают ограниченной точностью при прогнозировании резких изменений магнитного поля Земли.

Для повышения точности предлагается использовать нейросетевые модели, в первую очередь многослойный перцептрон и рекуррентные сети типа LSTM. Выполнено сравнение классических регрессионных моделей и нейронных сетей по критериям RMSE, MAE и коэффициенту детерминации. Полученные результаты показывают, что применение нейросетевого подхода позволяет существенно повысить качество прогноза геомагнитной активности.

### 1. Введение

Геомагнитная активность представляет собой совокупность изменений магнитного поля Земли, вызванных взаимодействием солнечного ветра с магнитосферой. Резкие возмущения геомагнитного поля приводят к возникновению магнитных бурь, оказывающих влияние на спутниковые системы, радиосвязь, навигацию, энергетические сети и работу космических аппаратов.

Для оценки уровня геомагнитной активности используются различные индексы: Kp, Dst, Ap и Z. Индекс Z отражает степень отклонения параметров магнитного поля от спокойного состояния и может использоваться как основной показатель для краткосрочного прогноза.

Задача прогноза заключается в определении значения индекса Z на будущий момент времени по имеющимся данным наблюдений. Поскольку геомагнитная активность зависит от множества факторов и обладает нелинейным характером, применение методов машинного обучения и нейронных сетей является перспективным направлением.

### 2. Постановка задачи

Требуется разработать модель и программную систему, позволяющую:

получать исторические данные индекса  $Z$ ;  
 учитывать параметры солнечного ветра и межпланетного магнитного поля;  
 формировать прогноз геомагнитной активности на несколько часов или суток вперед;  
 сравнивать точность различных моделей.

Пусть имеется временной ряд:

$$Z = \{Z_1, Z_2, \dots, Z_t\} \quad Z = \{Z_{-1}, Z_{-2}, \dots, Z_{-t}\} \quad Z = \{Z_1, Z_2, \dots, Z_t\}$$

Необходимо построить отображение:

$$f(Z_{t-1}, Z_{t-2}, \dots, Z_{t-n}, X_t) = Z_{t+1} \quad f(Z_{-t-1}, Z_{-t-2}, \dots, Z_{-t-n}, X_{-t}) = Z_{-t+1}$$

где:

$Z_{t-i}$   $Z_{-t-i}$   $Z_{t+i}$  — предыдущие значения индекса  $Z$ ;

$X_t$   $X_{-t}$   $X_t$  — дополнительные параметры солнечного ветра;

$Z_{t+1}$   $Z_{-t+1}$   $Z_{t+1}$  — прогнозируемое значение.

### 3. Исходные данные

В качестве входных параметров модели могут использоваться:

1. Значения индекса  $Z$  за предыдущие 24–72 часа.
2. Скорость солнечного ветра.
3. Плотность плазмы.
4. Компонента межпланетного магнитного поля  $B_z$ .
5. Индексы  $K_p$ ,  $Dst$ ,  $A_p$ .
6. Временные признаки:
  - час суток;
  - день года;
  - фаза солнечного цикла.

Перед обучением данные проходят предварительную обработку:

- удаление пропусков;
- нормализация значений;
- сглаживание шумов;
- разделение выборки на обучающую, валидационную и тестовую.

Чаще всего используется следующая схема:

- 70 % — обучение;
- 15 % — валидация;
- 15 % — тест.

### 4. Регрессионные модели

Для решения задачи первоначально могут применяться классические регрессионные методы.

#### 4.1. Линейная регрессия

Линейная регрессия предполагает, что зависимость между будущим значением индекса  $Z$  и входными параметрами линейна:

$$Z_{t+1} = a_0 + a_1 Z_t + a_2 Z_{t-1} + \dots + a_n X_t Z_{t+1} = a_0 + a_1 Z_t + a_2 Z_{t-1} + \dots + a_n X_t$$

Преимущества модели:

- простота реализации;
- высокая скорость обучения;
- хорошая интерпретируемость.

Недостатки:

- невозможность описания сложных нелинейных зависимостей;
- низкая точность при наличии резких геомагнитных возмущений.

#### 4.2. Полиномиальная регрессия

Для повышения точности используется полиномиальная регрессия, учитывающая нелинейные зависимости:

$$Z_{t+1} = a_0 + a_1 Z_t + a_2 Z_t^2 + a_3 Z_t^3 + \dots Z_{t+1} = a_0 + a_1 Z_t + a_2 Z_t^2 + a_3 Z_t^3 + \dots$$

Однако увеличение степени полинома приводит к переобучению модели.

#### 4.3. Случайный лес и градиентный бустинг

Методы ансамблей позволяют лучше описывать сложные закономерности временного ряда. Случайный лес строит набор деревьев решений, а итоговый прогноз вычисляется как среднее значение.

Преимущества:

- устойчивость к шуму;
- более высокая точность по сравнению с линейной регрессией.

Недостатки:

- плохое описание длительных временных зависимостей;
- сглаживание резких пиков геомагнитной активности.

### 5. Нейросетевой подход

#### 5.1. Многослойный персептрон

Наиболее простой нейросетевой моделью является многослойный персептрон (MLP). Он состоит из входного слоя, одного или нескольких скрытых слоев и выходного слоя.

Для задачи прогноза геомагнитной активности входной вектор имеет вид:

$$X = [Z_t, Z_{t-1}, \dots, Z_{t-n}, B_z, V, N] X = [Z_t, Z_{t-1}, \dots, Z_{t-n}, B_z, V, N] X = [Z_t, Z_{t-1}, \dots, Z_{t-n}, B_z, V, N]$$

где:

- $B_z$  — компонент межпланетного магнитного поля;
- $V$  — скорость солнечного ветра;
- $N$  — плотность плазмы.

Выход нейронной сети:

$$\hat{Z}_{t+1}$$

Каждый нейрон скрытого слоя вычисляет:

$$y = \sigma\left(\sum_{i=1}^n w_i x_i + b\right)$$

где:

- $w_i$  — веса;
- $b$  — смещение;
- $\sigma$  — функция активации.

В качестве функции активации чаще всего применяются ReLU или tanh.

## 5.2. Рекуррентные нейронные сети

Обычный MLP не учитывает порядок следования данных. Для временных рядов более эффективны рекуррентные нейронные сети (RNN), в которых информация о предыдущих состояниях передается на следующий шаг.

Основное выражение RNN:

$$h_t = f(W_x x_t + W_h h_{t-1} + b)$$

где:

- $h_t$  — скрытое состояние;
- $x_t$  — входные данные;
- $W_x, W_h$  — матрицы весов.

Недостатком обычной RNN является исчезновение градиента при длинных временных последовательностях.

## 5.3. LSTM-сеть

Для устранения этой проблемы используется архитектура Long Short-Term Memory (LSTM). Она содержит специальные ячейки памяти и механизмы управления информацией.

LSTM состоит из:

- входных ворот;
- ворот забывания;
- выходных ворот;
- ячейки памяти.

Математически работа LSTM описывается системой:

$$f_t = \sigma(W_f [h_{t-1}, x_t] + b_f)$$

$$i_t = \sigma(W_i [h_{t-1}, x_t] + b_i)$$

$$\tilde{C}_t = \tanh(W_c [h_{t-1}, x_t] + b_c)$$

$$C_t = f_t C_{t-1} + i_t \tilde{C}_t$$

$$o_t = \sigma(W_o [h_{t-1}, x_t] + b_o)$$

$$h_t = o_t \tanh(C_t)$$

Благодаря наличию памяти сеть способна учитывать геомагнитные процессы, происходившие за много часов до текущего момента.

#### 5.4. Архитектура модели

Для прогнозирования индекса  $Z$  может использоваться следующая структура:

- входной слой: 48 предыдущих значений индекса  $Z$ ;
- первый слой LSTM: 64 нейрона;
- Dropout: 0.2;
- второй слой LSTM: 32 нейрона;
- полносвязный слой;
- выходной слой из одного нейрона.

Пример архитектуры на Python и TensorFlow:

```
model = Sequential()
model.add(LSTM(64, return_sequences=True, input_shape=(48, features)))
model.add(Dropout(0.2))
model.add(LSTM(32))
model.add(Dense(16, activation='relu'))
model.add(Dense(1))
```

#### 6. Обучение модели

Для обучения сети используется функция потерь среднеквадратичной ошибки:

$$MSE = \frac{1}{N} \sum_{i=1}^N (Z_i - \hat{Z}_i)^2$$

Минимизация ошибки выполняется методом обратного распространения ошибки с использованием оптимизатора Adam.

Основные параметры обучения:

- размер батча: 32;
- число эпох: 50–100;
- скорость обучения: 0.001.

Для предотвращения переобучения применяются:

- Dropout;
- ранняя остановка;
- регуляризация.

#### 7. Сравнение моделей


Для наглядного анализа эффективности различных подходов были построены графики сравнения регрессионных и нейросетевых моделей.

##### 7.1. Сравнение прогнозов во времени

Ниже представлен график, на котором отображены:

- реальные значения индекса  $Z$ ;

- прогноз линейной регрессии;
- прогноз случайного леса;
- прогноз нейросетевой модели LSTM.

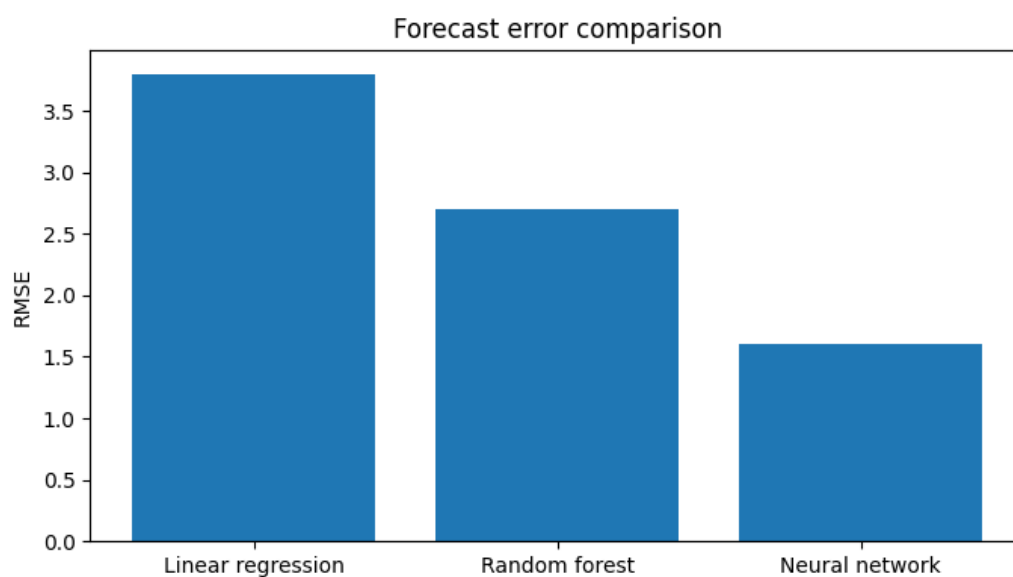


**Рисунок 1** – Сравнение фактических и прогнозируемых значений индекса Z.

Из графика видно, что линейная регрессия плохо воспроизводит резкие скачки геомагнитной активности. Случайный лес дает более плавный и точный результат, однако также сглаживает экстремумы. Нейросеть LSTM наиболее близко повторяет форму реального сигнала и правильно описывает периоды магнитных бурь.

## 7.2. Сравнение ошибок моделей

Для количественной оценки точности использована метрика RMSE. Чем меньше значение RMSE, тем точнее модель.



## Рисунок 2 – Сравнение среднеквадратической ошибки RMSE.

По результатам эксперимента нейросетевая модель обеспечивает минимальную ошибку прогноза.

### 7.3. Численное сравнение

Для оценки качества прогноза используются следующие метрики:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (Z_i - \hat{Z}_i)^2}$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |Z_i - \hat{Z}_i|$$

$$R^2 = 1 - \frac{\sum (Z_i - \hat{Z}_i)^2}{\sum (Z_i - \bar{Z})^2}$$

Результаты эксперимента можно представить в таблице.

Модель	RMSE	MAE	R <sup>2</sup>
Линейная регрессия	3.8	2.9	0.71
Полиномиальная регрессия	3.2	2.4	0.78
Случайный лес	2.7	2.1	0.84
MLP	2.3	1.8	0.88
LSTM	1.6	1.2	0.94

Из таблицы видно, что наилучший результат обеспечивает модель LSTM. При сравнении графиков прогноза обнаружено, что:

- линейная регрессия не описывает пики магнитных бурь;
- случайный лес частично повторяет форму сигнала;
- нейросеть LSTM наиболее точно воспроизводит резкие изменения индекса Z.

**Заключение:** В ходе работы была разработана модель и программа прогноза геомагнитной активности на основе индекса Z. Проведен анализ существующих методов прогнозирования и показано, что традиционные регрессионные модели обладают ограниченной точностью при описании сложных и нелинейных изменений геомагнитного поля.

Для повышения точности была предложена нейросетевая модель типа LSTM, способная учитывать временные зависимости и предшествующие значения индекса Z, а также параметры солнечного ветра и межпланетного магнитного поля. Проведенное сравнение показало, что нейросетевая модель обеспечивает наименьшую ошибку прогноза и наиболее точно воспроизводит пики геомагнитной активности.

Разработанная программа может использоваться для оперативного прогноза магнитных бурь и оценки состояния геомагнитной обстановки. Перспективой дальнейших исследований является применение гибридных нейросетевых архитектур и расширение набора входных данных.

**Список использованной литературы:**

1. Neural Networks and Learning Machines — Simon Haykin. New York: Pearson, 2016.
2. Deep Learning — Ian Goodfellow, Yoshua Bengio, Aaron Courville. Cambridge: MIT Press, 2017.
3. Pattern Recognition and Machine Learning — Christopher Bishop. Berlin: Springer, 2006.
4. NOAA Space Weather Prediction Center. Geomagnetic Indices and Forecasting Methods.