

# Метод выявления аномалий в вариациях космических лучей на основе совмещения вейвлет-преобразования с нейронными сетями

МАНДРИКОВА О.В.<sup>1,2</sup>, ЗАЛЯЕВ Т.Л.<sup>1</sup>, БЕЛОВ А.В.<sup>3</sup>, ЯНКЕ В.Г.<sup>3</sup>

<sup>1</sup>Институт космофизических исследований и распространения радиоволн ДВО РАН,  
Россия

<sup>2</sup>Камчатский государственный технический университет, Россия

<sup>3</sup>Институт земного магнетизма, ионосфера и распространения радиоволн им. Н.В.  
Пушкина РАН, Россия

oksanam1@mail.ru, tim.aka.geralt@mail.ru, abelov@izmiran.ru, yanke@izmiran.ru

## Введение

В работе предложен метод моделирования вариаций космических лучей (КЛ) и выявления аномалий, возникающих в периоды повышенной солнечной активности. Вариации КЛ имеют сложную нестационарную структуру, содержат разномасштабные локальные особенности в виде пиков, всплесков различной амплитуды и длительности. Построение методов анализа таких данных и оперативного выявления аномалий представляет собой весьма сложную задачу. Исследования данной работы основаны на совместном применении методов вейвлет-преобразования и нейронных сетей. Вейвлет-аппарат является эффективным средством изучения нестационарных процессов и дает возможность выполнить детальный анализ нерегулярных локальных структур [1, 2]. На основе кратномасштабных вейвлет-разложений в работе выполняется выделение *характерных* составляющих вариаций КЛ и подавляется шум. Полученные *характерные* составляющие моделируются многослойными прямонаправленными нейронными сетями. Преимущество нейросетевого представления аппроксимируемой функции заключается в большой гибкости базовых функций и их способности к адаптации. Аппарат нейронных сетей также дает возможность путем анализа ошибок решения обученной сети выявить скрытые закономерности в данных, связанные с изменением их структуры [2, 3]. Путем минимизации погрешности аппроксимации в работе определены вейвлет-функции для решения данной задачи и построены адаптивные нейросетевые системы по аппроксимации и прогнозу данных КЛ.

На основе разработанных средств авторами проведено исследование данных станции нейтронных мониторов Мыс Шмидта за 2005 г. В процессе моделирования и анализа работы программных систем выявлены аномальные особенности в вариациях КЛ, возникающие в периоды магнитных бурь, а также наблюдающиеся накануне сильных наземных возрастаний интенсивности солнечных КЛ (событий GLE [4]).

## Описание метода. 1. Кратномасштабные разложения ряда на компоненты.

Не нарушая общности, будем считать, что исходные данные принадлежат пространству с разрешением  $j = 0$ . На основе кратномасштабных разложений до уровня  $m$  получаем представление данных в виде [1]:

$$f_0(t) = \sum_{j=-1}^{-m} f^d [2^j t] + f^a [2^{-m} t], \quad (1)$$

где  $f^d[2^j t] \in W_j$ ,  $f^a[2^{-m}t] \in V_{-m}$ ,  $W_j = clos_{L^2(R)}(2^j \Psi(2^j t - k)) : k \in Z$ ,  $\Psi$  - базисный вейвлет;  $V_j = clos_{L^2(R)}(2^j \phi(2^j t - k)) : k \in Z$ ,  $\phi$  - скэйлинг-функция,  $j$  - разрешение (масштаб). Компонента ряда  $f^a[2^{-m}t] = \sum_k c_{-m,k} \phi_{-m,k}(t)$ , где  $c_{-m,k} = \langle f, \phi_{-m,k} \rangle$ , является аппроксимирующей компонентой, описывает тренд ряда, компоненты  $f^d[2^j t] = \sum_k d_{j,k} \Psi_{j,k}(t)$ , где  $d_{j,k} = \langle f, \Psi_{j,k} \rangle$ , являются детализирующими компонентами, описывают разномасштабные колебания.

С целью восстановления исходного разрешения  $j = 0$ , для полученных после преобразования компонент выполняем операцию вейвлет-восстановления (отдельно для каждой компоненты). Получаем представление ряда в виде следующих компонент  $f_0^a(t) = \sum_k c_{0,k} \phi_{0,k}(t)$ ,  $f_0^{d,j}(t) = \sum_k d_{0,k}^j \Psi_{0,k}(t)$ ,  $j = \overline{-1, -m}$ , где верхний индекс  $j$  соответствует масштабу детализирующей компоненты до её восстановления.

*Замечание.* На основе преобразования (1) имеем следующее разложение пространства  $W_0$ :  $W_{j=0} = \bigoplus_{j=-1}^{-m} W_j$ , где  $\{\Psi_{j,k}\}_{k \in Z}$  есть базис пространства  $W_j$ . Путем изменения уровня разложения  $m$ , мы можем построить различные кратномасштабные представления ряда. Для выбора разложения, обеспечивающего наилучшее представление, определяемое структурой функции  $f_0$ , можно использовать адаптивные алгоритмы, предложенные, например, в работе [1]. Полученная таким образом аппроксимация данных также может быть улучшена на основе применения различных вейвлет-функций.

## Аппроксимация компонент нейронной сетью

На основе нейронной сети для каждой полученной компоненты строим отображение

$$y : f^{(\cdot)} \rightarrow f^{*(\cdot)}, \text{ где } f^{(\cdot)} \in \{f^a, f^{d,j}\}_{j=\overline{-1, -m}}.$$

Множество весовых коэффициентов входных связей нейрона представляет собой вектор-столбец  $U = [u_1, \dots, u_N]^T$ , где  $N$  – длина входного вектора сети. Если  $\hat{f}^{(\cdot)}$  действительный выход сети, а  $f^{*(\cdot)}$  – желаемый, то  $f^{*(\cdot)} = y(f^{(\cdot)})$  – неизвестная функция, а  $\hat{f}^{(\cdot)} = G(f^{(\cdot)}, U)$  – ее аппроксимация, которую воспроизводит нейронная сеть. Процедура обучения сети сводится к минимизации среднеквадратической ошибки аппроксимации по параметру  $U$  [3]. При подаче на вход обученной нейронной сети значений функции  $f$  из интервала  $[l - T + 1, l]$ , сеть становится способной вычислить упрежденные значения функции на временном интервале  $[l + 1, l + I]$ , где  $l$  – текущий дискретный момент времени;  $I$  – длина интервала упреждения. *Ошибка сети* определяется как разность между желаемым  $f'$  и действительным  $\hat{f}'$  выходными значениями в дискретный момент времени  $l$ . Вектор ошибки – это вектор,  $i$ -й элемент которого равен  $\varepsilon_i(l) = \hat{f}_i^{*(\cdot)}(l) - f_i^{*(\cdot)}(l)$ , где  $l$  – текущий момент времени,  $i$  – текущая позиция на интервале упреждения.

## Алгоритм построения нейронной сети:

1. Данные обучающей выборки делим на блоки и формируем массивы данных, размерность которых  $N \times V$ , где  $N$  – длина входного вектора сети,  $V$  – количество обучающих векторов.
2. Строим сеть *переменной структуры* (сеть *переменной структуры* – это многослойная прямонаправленная сеть, архитектура которой определяется путем минимизации ошибки решения на множестве обучающих векторов [3]) и выполняем ее обучение.
3. Выполняем тестирование сети. Если тестирование сети подтверждает адекватность построенного отображения данным, то будем считать, что обучающие векторы содержат *характерные признаки данных* и сеть готова к использованию.

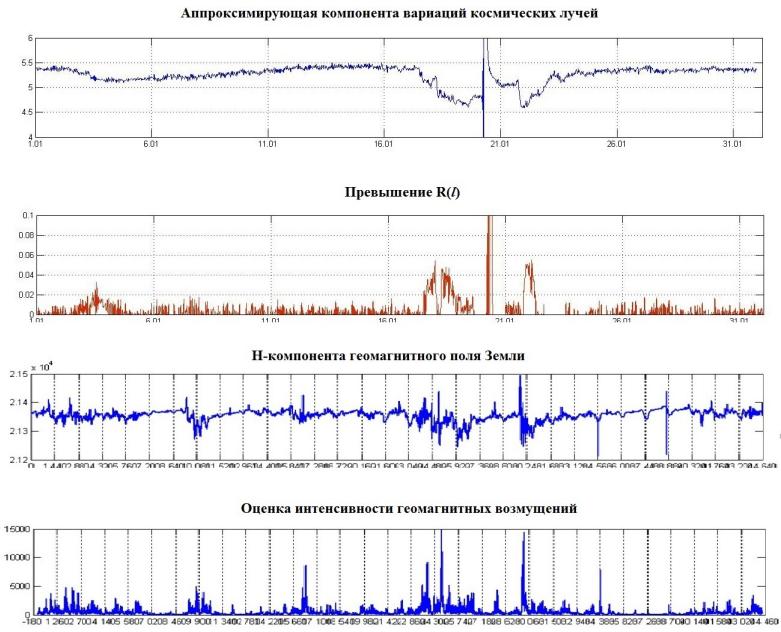


Рис. 1. Результаты обработки данных КЛ за январь 2005 года

Используя приведенный алгоритм, для каждой компоненты  $f^{(\cdot)} \in \{f^a, f^{d,j}\}_{j=-1,-m}$  получаем аппроксимацию, которую воспроизводит нейронная сеть. На основе анализа ошибок решения каждой обученной сети выполняем *операцию выделения аномалий*, которую посторим следующим образом: *для каждого момента времени  $l$  оценим величину*

$$R_i^j(l) = \text{med}_{l,l=1,\alpha} |\varepsilon_i^j(l)|, \quad \text{где med - медиана, } \alpha - \text{длина окна, } \varepsilon_i^j(l) - \text{ошибка сети, } j - \text{масштаб компоненты до её восстановления; если величина } R_i^j(l) \geq P_i^j, \text{ где } P_i^j - \text{наперед заданное пороговое значение, то будем считать, что в момент времени } l \text{ в данных наблюдается аномалия масштаба } j.$$

## Результаты экспериментов

Динамика наблюдаемых на поверхности Земли вариаций КЛ существенно зависит от состояния геомагнитного поля и электромагнитной обстановки в Солнечной системе [5]. Поэтому при построении нейронных сетей обучающие множества формировались из данных, регистрируемых в периоды спокойного геомагнитного поля. В экспериментах использовались минутные данные нейтронных мониторов станции Мыс Шmidta за 2005г. Этот период времени является периодом минимума солнечной активности, что обеспечивает наилучшие условия для построения аппроксимации характерного хода КЛ. Используя данный подход, были сформированы обучающие множества для нейронных сетей и построены сети по аппроксимации каждой компоненты  $f^{(\cdot)} \in \{f^a, f^{d,j}\}_{j=-1,-m}$ . В качестве базисных функций использовались ортонормированные вейвлеты семейства Добеши и семейства Койфлеты. Наилучшие результаты при тестировании полученных нейронных сетей показала сеть, воспроизводящая аппроксимацию компоненты  $f^a$  КЛ, полученной при использовании вейвлетов Койфлет порядка 3. Результаты работы данной сети представлены на рис. 1-4. При выполнении анализа результатов и интерпретации выявленных аномалий использовались Н-компоненты геомагнитного поля (данные станции “Паратунка”, Камчатский край), на основе которых выполнялась оценка интенсивности геомагнитных возмущений в анализируемые периоды времени. Анализ рис. 1-4 показывает наличие аномальных особенностей в вариациях КЛ, которые возникают в периоды повышенной геомагнитной актив-

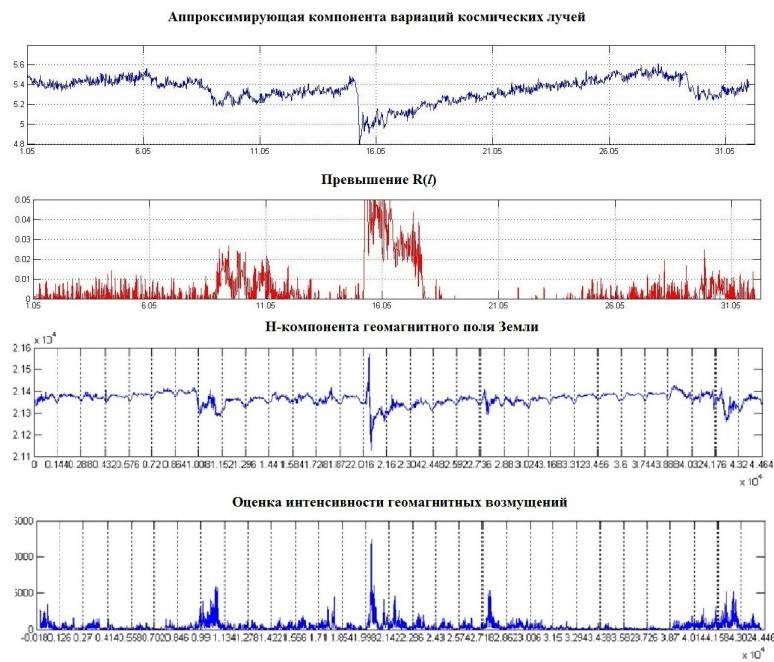


Рис. 2. Результаты обработки данных КЛ за май 2005 года

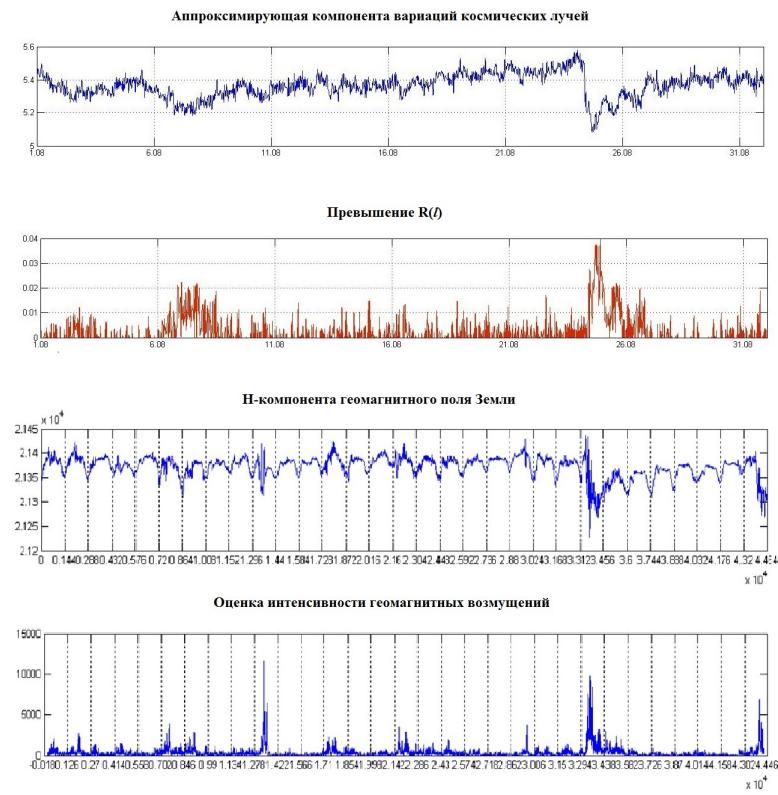


Рис. 3. Результаты обработки данных КЛ за август 2005 года

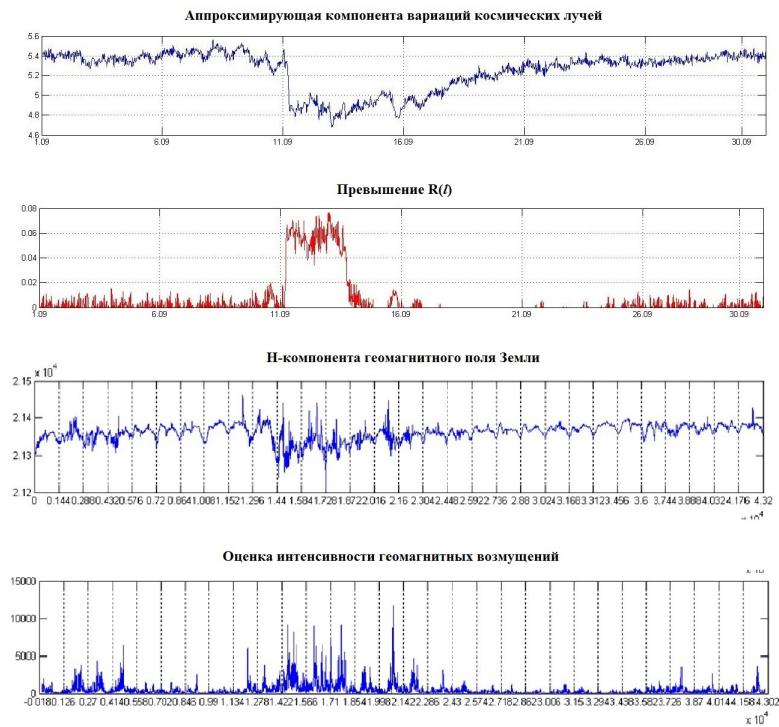


Рис. 4. Результаты обработки данных КЛ за сентябрь 2005 года

ности и соответствуют моментам максимального возрастания интенсивности возмущений поля (17.01.2005, 18.01.2005, 21.01.2005, рис.1; 08.05.2005г., 15.05.2005г., рис.2; 06.08.2005г. 24.08.2005г., рис.3; 11.09.2005г., рис.4). В эти моменты времени наблюдается понижение уровня КЛ (Форбуш эффекты), которые объясняют возникновение аномалий, связанных с изменением хода процесса. Накануне и после события GLE (20.01.2005г., рис.1) также наблюдаются аномалии, моменты возникновения которых совпадают с моментами максимума интенсивности возмущений геомагнитного поля на главной фазе бурь 17.01.2005, 18.01.2005 и 21.01.2005.

## Выводы

Предложенный в работе метод аппроксимации вариаций КЛ, основанный на совмещении конструкции кратномасштабного анализа и нейронных сетей, позволил изучить внутреннюю структуру данных, построить аппроксимации их характерного хода и выявить аномалии, возникающие в вариациях КЛ в периоды повышенной солнечной активности.

Работа частично выполнена при поддержке гранта РФФИ – ДВО РАН №11-07-98514-р\_восток\_a.

## Литература

1. *Mallat S. A Wavelet tour of signal processing [пер. с анг.]* -М.: Мир, 2005. -671 с.
2. *Мандрикова О.В. Оптимизация процесса обучения нейронной сети на основе применения конструкции вейвлет-преобразования (на примере модельного представления ионосферного сигнала).* – Москва: Автоматизация и современные технологии.-2009. -№3.- С.14-17.

3. Нейроматематика: учеб. пособие для вузов / Агеев А.Д., [и др.]; общая ред А.И. Галушкина. – М.:ИПРЖР, 2002. -448 с.
4. *Eroshenko E.A., Belov A.V., Kryakunova O.N., Kurt V.G., Yanke V.G.* The alert signal of GLE of cosmic rays// PROCEEDINGS OF THE 31st ICRC, J' OD'Z 2009
5. *Топтыгин И.Н.* Космические лучи в межпланетных магнитных полях/ И.Н. Топтыгин – М.:Наука, 1983. – 301 с.

## **Cosmic ray variation modeling according to neutron monitors data and detection of their intensity ground enhancement precursors**

*Mandrikova O.V.<sup>1,3</sup>, Zalyaev T.L.<sup>1</sup>, Belov A.V.<sup>2</sup>, Yanke V.G.<sup>2</sup>*

<sup>1</sup> *Institute of Cosmophysical Researches and Radio Wave Propagation FEB RAS, Russia*

<sup>2</sup> *Pushkov Institute of Terrestrial Magnetism, Ionosphere and Radio Waves Propagation RAS, Russia*

<sup>3</sup> *Kamchatka State Technical University, Russia*

The paper proposes a way to model the data of cosmic ray time variation, that is based on the combination of wavelet transform and multilayer feedforward neural networks, allowing to describe the characteristic variation and to detect some peculiarities formed before strong increases in the ground level intensity. Based on wavelet transform, detection of characteristic components of cosmic ray variations is carried out and noise is suppressed. Selecting the best basic wavelet function and making an approximation, which provides the smallest error, the characteristic components are determined. The resulting characteristic components are modeled via neural networks. On the basis of the analysis of neural network error vector, precursors of strong increases in cosmic ray ground level intensity are identified. At the modeling stage, data of Moscow and Apatity neutron monitor stations for the period 2000-2005 were used. The modeling confirmed the efficiency of the proposed method and revealed the precursors of cosmic ray ground level enhancement.