

Метод анализа данных космических лучей на основе нейронных сетей векторного квантования

О.В. Мандрикова¹, В.В. Геппенер², Б.С. Мандрикова²

¹Институт космофизических исследований и распространения радиоволн ДВО РАН, Мирная 7, Паратунка, Камчатский край, Россия, 684034

²Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» им. В.И. Ульянова (Ленина), Профессора Попова 5, Санкт-Петербург, Россия, 197022

Аннотация. Описан автоматизированный метод анализа данных космических лучей и выделения спорадических эффектов. Метод основан на применении кратномасштабных вейвлет-разложений и нейронных сетей векторного квантования. На основе метода изучена динамика космических лучей в периоды повышенной солнечной активности и магнитных бурь. Выделены спорадические эффекты, предшествующие и сопутствующие магнитным бурям. Показана эффективность метода для режима оперативного анализа данных и выделения спорадических эффектов, в т. ч. малой амплитуды. Результаты важны в задачах прогноза космической погоды.

1. Введение

Изучение данных космических лучей представляет интерес в задачах солнечно-земной физики и прикладных исследованиях, связанных с космической погодой. Изменение условий на Солнце, в солнечном ветре, магнитосфере и ионосфере Земли существенно влияет на работу и надежность бортовых и наземных технологических систем, и угрожает здоровью и жизни людей. В настоящее время задача оперативного и точного прогноза космической погоды не решена [1, 2]. Для оперативного прогнозирования космической погоды весьма важно создание автоматизированных методов анализа регистрируемых данных космических лучей и своевременного обнаружения спорадических эффектов. К спорадическим эффектам относят Форбуш-эффекты и большие протонные возрастания Ground Level Enhancement (GLE-события). Форбуш-эффекты, впервые отмеченные С. Форбушем [3], представляют собой аномальные изменения (повышения и понижения) интенсивности космических лучей, которые обычно связаны с сильными магнитными бурями. Наземные возрастания солнечных космических лучей (GLE) представляют серьезную угрозу здоровью и жизни людей [4].

Для изучения динамики космических лучей используют космические и наземные данные мировой сети нейтронных мониторов [11]. Регистрируемые вариации космических лучей представляют собой сложную нелинейную зависимость. На поверхности Земли интенсивность космических лучей зависит от температуры, давления воздуха, широты пункта наблюдения и состояния геомагнитного поля, электромагнитной обстановки в Солнечной системе и физ. условий в Галактике [5]. Амплитуда вариаций первичных космических лучей зависит от энергии частиц и напряженности межпланетных магнитных полей [6]. Классические методы анализа данных нейтронных мониторов (спектральные методы [7, 8], сглаживающие методы [6,

9)] не являются достаточно эффективными. Современные методы, например, метод кольца станций [10], позволяют с приемлемой точностью определять основные характеристики вариаций космических лучей. Однако эти методы требуют трудоемких расчетов и их автоматизация не реализована.

Учитывая неполные знания о процессах в околоземном пространстве и, как следствие, о внутренней структуре регистрируемых данных, в работе для анализа данных нейтронных мониторов предложено использовать аппарат нейронных сетей. Известно, что нейронные сети способны аппроксимировать сложные нелинейные зависимости данных без полного априорного знания о внутренних связях и зависимостях [12-18]. Также большим преимуществом данного аппарата является возможность численной реализации [19,20], что важно для задач оперативного анализа данных. В настоящее время нейронные сети активно применяются в различных прикладных областях для задач анализа данных сложной структуры, в том числе в области геофизики [17,18]. Рассматриваемый в работе подход основан на применении нейронных сетей векторного квантования [21], впервые предложенный в работе [22]. В данной статье предложен и обоснован способ повышения эффективности метода на основе предобработки данных методом кратномасштабных вейвлет-разложений [23]. Построены нейронные сети и выполнена оценка их работы в режиме оперативного анализа. Результаты подтвердили возможность применения разработанного метода в задачах выделения разномасштабных спорадических эффектов, в т. ч. малой амплитуды.

2. Описание метода

2.1. Кратномасштабное вейвлет-разложение функции

Имея дискретные значения функции f_j (т.е. значения функции на сетке с разрешением 2^{-j}), в качестве пространства выборки рассмотрим подпространство $V_j = \text{clos}_{L^2(R)}(\varphi(2^j t - n)), n \in Z$, $L^2(R)$ - пространство Лебега, масштабирующая функция φ порождает подпространства V_j своими сдвигами и растяжениями [Чуи, Малла].

Отобразив f_j в пространства V_{j-1} и W_{j-1} , получим [26, 27]:

$$V_j = V_{j-1} \oplus W_{j-1}, \tag{1}$$

(знак « \oplus » в (1) обозначает ортогональную сумму). Базисом пространства W_j является набор вейвлетов $\Psi_{j,n} = 2^{j/2} \Psi(2^j t - n), n \in Z$. На основе отображения (1) функция f_j имеет представление

$$f_j(t) = f_{j-1}(t) + g_{j-1}(t) = \sum_n c_{j-1,n} \varphi_{j-1,n}(t) + \sum_n d_{j-1,n} \Psi_{j-1,n}(t), \tag{2}$$

Каждая компонента в (2) единственным образом определяется последовательностями коэффициентов $\bar{c}^j = \{c_{j,n}\}_{n \in Z} \in V_j$ и $\bar{d}^j = \{d_{j,n}\}_{n \in Z} \in W_j$: $c_{j,n} = \langle f, \varphi_{j,n} \rangle$, $d_{j,n} = \langle f, \Psi_{j,n} \rangle$. Вычислительная процедура (2) работает на любом разрешении (масштабе) j [25, 26]. Если данную процедуру выполнить для функции f_j m раз, то получим её представление в виде:

$$f_j(t) = g_{j-1}(t) + g_{j-2}(t) + \dots + g_{j-m}(t) + f_{j-m}(t) = \sum_{k=j-1}^{j-m} \sum_n d_{k,n} \Psi_{k,n}(t) + \sum_n c_{j-m,n} \varphi_{j-m,n}(t). \tag{3}$$

В соотношении (3) компоненты g_{j-i} являются *детализирующими (высокочастотными) компонентами*, компонента f_{j-m} является *сглаженной компонентой*. Разложение (3) называется в вейвлет-преобразовании *ортогональным кратномасштабным вейвлет-разложением* до уровня m [25, 26]. На рис. 1 показаны результаты кратномасштабного вейвлет-разложения данных нейтронного монитора (НМ) до уровней $m=1,2,3$. Анализ результатов на рис.1 показывает наличие высокого уровня шума в регистрируемых данных и возможность

применения процедуры кратномасштабного вейвлет-разложения для его подавления. На рис. 2 представлены амплитудно-частотные характеристики (АЧХ) вейвлет-функции и масштабирующей функции на 1-ом и 2-ом уровнях вейвлет-разложения.




Рисунок 1. Черным цветом представлены данные НМ за 12 июля 2016г. (станция Kingston); желтым – применение функции Койфлет 3, уровень разложения $m=1$, красным – Койфлет 3, уровень разложения $m=2$; голубой – Койфлет 3, уровень разложения $m=3$.




Рисунок 2. АЧХ вейвлет-функции Ψ и масштабирующей функции ϕ на 1-м (черным) и 2-м (красным) уровнях разложения, использовался базис Койфлет 3.

2.2. Выбор вейвлет-функции

В работе, с целью получения численно устойчивых разложений, рассматривался класс ортогональных вейвлет-функций. При выборе ортогональной вейвлет-функции использовались следующие критерии, предложенные в работе [25]:

1. Большое число нулевых моментов вейвлет-функции. Число нулевых моментов s вейвлет-функции Ψ , т.е.

$$\int_{-\infty}^{+\infty} t^k \Psi(t) dt = 0, k = 0, s - 1 \tag{4}$$

характеризует его способность выявлять особенность вида $\alpha \leq s$, где α - порядок гладкости функции.

2. Малый носитель вейвлет-функции. Вейвлет-преобразование порождает искусственные “скачки” на краях функции f , так называемые *краевые эффекты* [24]. Размер окрестности на масштабе j , содержащей краевой эффект, определяется по формуле

$$h_j = 2^j * q \tag{5}$$

где q - носитель используемой базисной функции. Поэтому, чем меньше носитель q , тем меньшую погрешность мы имеем на краях функции.

3. Высокий порядок гладкости вейвлет-функции. Аналогично числу нулевых моментов, гладкость вейвлет-функции характеризует её способность выявлять особенность вида $\alpha \leq s$.

При выборе вейвлет-функции мы приходим к выбору между числом нулевых моментов и размером носителя. Известно [24], что число нулевых моментов и гладкость вейвлет-функции связаны друг с другом, но характер связи может быть различным. Например, для вейвлет-функций семейства Добеши [26] характерно свойство: гладкость вейвлет-функции возрастает с

возрастанием числа нулевых моментов. В большинстве практических задач необходимо, чтобы сглаженная компонента f_{j-m} (см. соотн. (3)) позволяла получить наилучшее приближение функции, а с помощью мелкомасштабных составляющих g_{j-i} идентифицировались отдельные локальные особенности функции. В этом случае важно, чтобы нулевые моменты имела не только вейвлет-функция ψ , но и масштабирующая функция φ . В классе ортогональных функций наиболее удовлетворяют критериям 1 – 3 семейства вейвлетов Добеши и Койфлеты:

- семейство Добеши – это единственное семейство ортогональных вейвлет-функций, которые имеют минимальный носитель при заданном числе нулевых моментов [29].
- семейство Койфлеты - единственное из ортогональных вейвлет-функций, которые имеют носитель наименьшего размера при достаточном числе нулевых моментов в масштабирующей функции φ [26]. Известно [26], если $f \in C^r$ (C^r – пространство r раз непрерывно дифференцируемых функций) в окрестности $2^{-m}n$ с $r \leq p$, то

$$2^{-m/2} \langle f, \varphi_{-m,n} \rangle \approx f(2^{-m}n) + O(2^{-m(r+1)}) \tag{6}$$

Порядок приближения возрастает с ростом p , результирующий Койфлет имеет носитель $3p-1$. На рис.3 представлены результаты кратномасштабного вейвлет-разложения данных НМ с использованием функций Добеши и Койфлеты. Анализ результатов на рис. 3 показывает хорошие аппроксимирующие свойства функции Койфлетов, что подтверждает свойство (6).




Рисунок 3. Черным показаны данные НМ за 12 июля 2016г. (станция Kingston); жёлтым – применение функции Добеши 3, уровень разложения $m=5$, красный – Койфлет 3, уровень разложения $m=5$.

3. Классификация данных нейтронных мониторов на основе нейронной сети векторного квантования LVQ

3.1. Предобработка данных на основе кратномасштабного вейвлет-разложения:

- предполагая, что исходный временной ряд f_j принадлежит пространству с разрешением $j=0$, на основе кратномасштабного вейвлет-разложения f_0 до уровня m (см. соотн. (3)) получаем сглаженную компоненту временного ряда в виде:

$$f_{-m}(t) = \sum_n c_{-m,n} \varphi_{-m,n}(t);$$
- с целью восстановления исходного разрешения функции выполняем операцию вейвлет-восстановления [23, 24]: $f_0^{(-m)}(t) = \sum_n c_{0,n}^{(-m)} \varphi_{0,n}(t)$, (верхний индекс $(-m)$ соответствует разрешению функции до выполнения операции вейвлет-восстановления);
- для исключения влияния краевого эффекта, у восстановленного набора данных удаляем первые и последние $2^m * q$ отсчетов (размер окрестности, содержащей краевой эффект на уровне разложения m , определяется по формуле (5)).

3.2. Архитектура и принцип работы нейронной сети LVQ

Нейронная сеть LVQ состоит из 2-х слоев, используемая в работе архитектура представлена на рис. 4 [27]. Первый слой – слой Кохонена (конкурирующий слой [27,28], см. рис.4), второй – линейный и формируется на этапе обучения нейронной сети: определяется соответствие между номерами нейронов 1-го слоя (кластерами) k и соответствующими классами l [29]

$$F_l = \sum_k w_{kl} y_k,$$

где w_{kl} – весовые коэффициенты нейрона l второго слоя сети, связанного с нейроном k первого слоя сети, y_k – выходное значение нейрона k первого слоя сети.

Кластеризация входных векторов на заданное число классов выполняется по метрике:

$$d_k = d(X, W_k) = \|X - W_k\| = \sqrt{\sum_{i=1}^I (x_i - w_{ik})^2} \tag{7}$$

где X — вектор входов; W_k – вектор весов нейрона k первого конкурирующего слоя, I – размерность входного вектора.

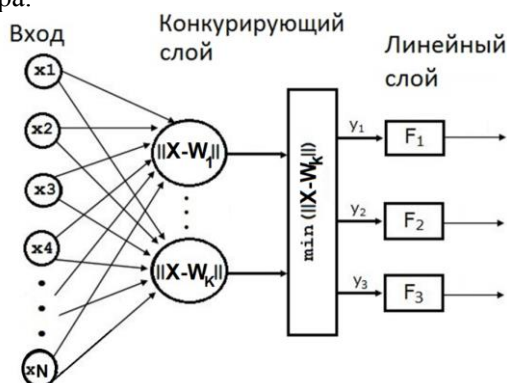


Рисунок 4. Структура нейронной сети LVQ.

В процессе работы нейронной сети (НС) в первом слое на основе оценки расстояния d_k (см. соотн. (7)) определяется нейрон-победитель p , для которого

$$D = d_{\min}(X, W_k) = \min_k \|X - W_k\|.$$

Выходное значение нейрона-победителя p устанавливается равным 1: $y_p = 1$, а других нейронов – равным нулю: $y_k = 0, k \neq p$. Нейрон-победитель устанавливает принадлежность входного вектора X классу, связанному с данным нейроном (кластером).

Выходной вектор НС имеет размерность, равную числу классов L (в работе $L = 3$, описание классов приведено ниже). В случае правильно обученной сети один элемент выходного вектора равен 1, остальные – нулю. Таким образом, НС позволяет решить задачу принадлежности входного вектора одному из априори известных классов.

3.3. Определение классов нейронной сети и схема решения задачи классификации данных

В работе, в соответствии с задачей исследования, определены следующие классы НС [21,22]:

1. «Спокойный» класс – отсутствие спорадических эффектов. «Спокойный» класс характеризуется: (1) – отсутствие активных пятен и вспышек на Солнце (вспышечная активность нулевая); (2) – отсутствие с видимой стороны на линии с Землей потока солнечного ветра; (3) – отсутствие магнитных бурь и возмущений в магнитосфере (индекс геомагнитной активности К (К-индекс) имеет значения ≤ 2).
2. «Слабовозмущенный» класс – наличие спорадических эффектов малой амплитуды. «Слабовозмущенный» класс характеризуется: (1) – возникновение незначительных вспышек на Солнце, направленных на Землю; (2) – наличие слабых возмущений в магнитосфере (К-индекс имеет значения 3, 4).
3. «Возмущенный» класс – наличие спорадических эффектов большой амплитуды. «Возмущенный» класс характеризуется: (1) – поступление в окрестность Земли возмущенных высокоскоростных потоков солнечного ветра и/или связанной с ними ударной волны; (2) – возникновение магнитной бури и наличие сильных возмущений в магнитосфере (К-индекс имеет значения ≥ 5).

В соответствии с предлагаемым подходом, решение задачи классификации данных может быть представлено в виде схемы, показанной на рис. 5.




Рисунок 5. Схема решения задачи классификации данных НМ.

4. Результаты применения метода

В экспериментах использовались минутные данные нейтронных мониторов станции Kingston за период 2015 и 2016 гг. [30]. При построении обучающей выборки отбор данных для каждого введенного класса (см. п. 1-3) основывался на анализе показателей геомагнитной активности – использовались А, К и Dst индексы [31]. Класс «спокойный» формировался из данных за временные интервалы, в которые А-индекс имел значения <7, К-индекс имел значения <3, Dst-индекс в пределах ± 4. Класс «слабовозмущенный» формировался из данных за временные интервалы, в которые А-индекс < 18, К-индекс < 5, Dst-индекс в пределах ± 8. Класс «возмущенный» включал временные интервалы, в которые А-индекс >18, К-индекс >5, Dst-индекс за пределами ± 8. Для обучения нейронных сетей использовалось 20 векторов: 10 векторов, геомагнитные индексы которых соответствовали классу «спокойный»; 6 векторов – соответствовали классу «слабовозмущенный»; 4 вектора – соответствовали классу «возмущенный». Для тестирования сети использовались 37 векторов (данные не использовались при обучении сети): 15 векторов, геомагнитные индексы которых соответствовали классу «спокойный»; 15 векторов – соответствовали классу «слабовозмущенный»; 7 векторов – соответствовали классу «возмущенный». Кратномасштабные вейвлет-разложения данных выполнялись с использованием вейвлет-функций Добеши и Койфлеты, выбор которых обоснован в п. 1. Результаты с наименьшей погрешностью получены с использованием вейвлет-функций Добеши 3 и Койфлеты 3. Построенные нейронные сети и результаты их работы приведены ниже:

1. LVQ1 – размерность входного вектора $N = 2880$ (соответствует двум суткам), на вход подавались исходные данные НМ. Успех распознавания класса «спокойный» составил 100%, класса «слабовозмущенный» - 60% (6 векторов определены к классу «спокойный») и класса «возмущенный» - 72% (2 вектора сеть определила к классу «слабовозмущенный»).
2. LVQ1_db3_1 – размерность входного вектора соответствует двум суткам, на вход подавались аппроксимирующие компоненты $f_{j-1}(t)$ (см. соотн. (2)), полученные с использованием базиса Добеши 3. Успех распознавания класса «спокойный» составил 60% (4 вектора НС определила к классу «слабовозмущенный»), класса «слабовозмущенный» - 53% (4 вектора сеть определила к классу «спокойный» и 3 к классу «возмущенный»), и класса «возмущенный» - 72% (2 вектора сеть определила к классу «слабовозмущенный»).
3. LVQ2 – размерность входного вектора $N = 4320$ (соответствует трем суткам), на вход подавались исходные данные НМ. Успех распознавания класса «спокойный» составил 100%, класса «слабовозмущенный» - 80% (3 вектора определены к классу «спокойный») и класса «возмущенный» - 93% (1 вектор НС определила к классу «слабовозмущенный»).
4. LVQ2_db3_1 – размерность входного вектора соответствует трем суткам, на вход подавались аппроксимирующие компоненты $f_{j-1}(t)$ (см. соотн. (2)), полученные с

- использованием базиса Добеши 3. Успех распознавания класса «спокойный» составил 100%, класса «слабовозмущенный» - 87% (2 вектора сеть определила к классу «спокойный»), и класса «возмущенный» - 93% (1 вектор сеть определила к классу «слабовозмущенный»).
5. LVQ2_db3_2 – размерность входного вектора соответствует трем суткам, на вход подавались аппроксимирующие компоненты $f_{j-1}(t)$ (см. соотн. (3)), полученные с использованием базиса Добеши 3. Успех распознавания класса «спокойный» составил 67% (5 векторов сеть определила к классу «слабовозмущенный»), класса «слабовозмущенный» - 47% (5 векторов сеть определила к классу «спокойный» и 3 вектора сеть определила к классу «возмущенный»), и класса «возмущенный» - 71% (1 вектор сеть определила к классу «слабовозмущенный» и 1 вектор – к классу «спокойный»).
 6. LVQ1_coif3_1 – размерность входного вектора соответствует двум суткам, на вход подавались аппроксимирующие компоненты $f_{j-1}(t)$ (см. соотн. (2)), полученные с использованием базиса Койфлеты 3. Успех распознавания класса «спокойный» составил 53% (7 векторов сеть определила к классу «слабовозмущенный»), класса «слабовозмущенный» - 53% (5 вектора сеть определила к классу «спокойный» и 2 – к классу «возмущенный»), и класса «возмущенный» - 43% (4 вектора сеть определила к классу «слабовозмущенный»).
 7. LVQ2_coif3_1 – размерность входного вектора соответствует трем суткам, на вход подавались аппроксимирующие компоненты $f_{j-1}(t)$ (см. соотн. (2)), полученные с использованием базиса Койфлет 3. Успех распознавания класса «спокойный» составил 100%, класса «слабовозмущенный» - 93% (1 вектор сеть определила к классу «возмущенный»), и класса «возмущенный» - 93% (1 вектор сеть определила к классу «слабовозмущенный»).
 8. LVQ2_coif3_2 – размерность входного вектора соответствует трем суткам, на вход подавались аппроксимирующие компоненты $f_{j-2}(t)$ (см. соотн. (3)), полученные с использованием базиса Койфлет 3. Успех распознавания класса «спокойный» составил 60% (6 векторов сеть определила к классу «слабовозмущенный»), класса «слабовозмущенный» - 47% (4 вектора сеть определила к классу «спокойный» и 3 вектора – к классу «возмущенный»), и класса «возмущенный» - 57% (2 вектора сеть определила к классу «слабовозмущенный» и 1 вектор – к классу «спокойный»).

В таблице 1 представлены результаты работы построенных НС, которые подтверждают эффективность аппарата нейронных сетей LVQ для задачи исследования. Анализ также показывает результативность применения процедуры предобработки данных на основе кратномасштабных вейвлет-разложений до 1-го уровня (см. соотн. (3)). Результаты с наименьшей погрешностью получены с использованием вейвлет-функции Койфлет 3, размерность входного вектора данной НС соответствует трем суткам (см. таблица 1). На 2-ом уровне вейвлет-разложения погрешность сети возрастает, что свидетельствует о потере части полезной информации при выполнении данной операции. Анализ АЧХ вейвлет-функции и масштабирующей функции на 1-ом и 2-ом уровнях вейвлет-разложения (см. рис.2) показывает, что для исходных минутных данных вейвлет-функция на 2-ом уровне разложения выделяет периоды колебаний от 3 до 14 мин, которые по результатам работы НС содержат полезную информацию в динамике космических лучей.

Таблица 1. Результаты работы нейронных сетей.

Входные данные НС	LVQ1			LVQ2		
	1 класс	2 класс	3 класс	1 класс	2 класс	3 класс
Исходные данные	100%	60%	72%	100%	80%	93%
db3_1	60%	53%	72%	100%	87%	93%
db3_2	-	-	-	67%	47%	71%
coif3_1	53%	53%	43%	100%	93%	93%
coif3_2	-	-	-	60%	53%	57%

На рис. 6 представлены результаты обработки данных НМ за период 16-22 января 2016г.. В анализируемый период 21 января 2016 г. произошла магнитные бури, вызванная высокоскоростным потоком солнечного ветра из корональной дыры (моменты начала магнитных бурь показаны на рис. 6 вертикальными линиями). Анализ космической погоды в этот период показал [34]: с начала суток 15 января по 20.55 UT 18 января скорость солнечного ветра плавно уменьшалась от 450 до 300 км/сек, южная компонента ММП флуктуировала в пределах $V_z = \pm 5$ nT; 20-21 января скорость солнечного ветра $v = 320-420$ км/сек, южная компонента ММП $V_z = \pm 12$ nT; с начала по конец суток 21 января скорость солнечного ветра плавно увеличилась от 400 км/сек до 550 км/сек, флуктуации ММП усилились до $V_z = \pm 19$ nT. Анализ вейвлет-спектра на рис. 6.b показывает, что с 19 по 21 января амплитуда вариаций космических лучей возросла в широком диапазоне частот, что свидетельствует о возникновении спорадических эффектов в этот период. Обработка данных на основе НС выполнялась в скользящем 3-х часовом временном окне. Результаты работы НС показывают возникновение спорадических эффектов малой амплитуды с 9.00 UT 17 января по 15.00 UT 18 января («слабовозмущенный» класс) и с 15.00 UT 18 января по 15.00 UT 22 января сеть классифицировала как «возмущенный» (см. рис. 6.d). Сопоставление результатов работы НС с данными космической погоды и вейвлет-спектром данных НМ подтверждает верность решения сети. Возможность оперативного выделения спорадических эффектов накануне магнитных бурь на примере данного события свидетельствует об эффективности предлагаемого метода.




Рисунок 6. а) данные НМ (станция Kingston, [30]) за 16-22 января 2016г., б) вейвлет-спектр данных НМ, с) данные Dst-индекса, б) результаты работы сети LVQ2_coif3_2.

На рис. 7 представлены результаты обработки данных НМ (станция Kingston) за 15-20 марта 2015г. В анализируемый период 17 марта 2015 г. произошла сильная магнитная буря с резким началом, вызванная выбросом корональной массы. Анализ космической погоды показал [34]: 15 марта скорость солнечного ветра флуктуировала на уровне 400 км/сек, вертикальная

компонента ММП изменялась в пределах $B_z = \pm 9$ nT; в начале суток 17 марта ММП резко опустилась до $B_z = -22$ nT, скорость солнечного ветра возросла до 500 км/сек, во второй половине суток 17 марта ММП опустилась до $B_z = -28$ nT, скорость солнечного ветра увеличилась до 670 км/сек; в конце суток 18 марта скорость солнечного ветра увеличилась до 800 км/сек. По результатам работы НС (рис. 7. d) 15 марта в динамике космических лучей возникли спорадические эффекты малой амплитуды («слабовозмущенный» класс). Период 17 – 18 марта сеть отнесла к «возмущенному» классу, что соответствует о возникновении крупных спорадических эффектов. Сопоставление результатов работы НС с данными космической погоды и вейвлет-спектром (рис. 7.b) подтверждает верность решения сети. Данные результаты, аналогично предыдущему событию, показывают возможность применения нейронной сети для оперативного обнаружения спорадических эффектов, в т.ч. малой амплитуды, и подтверждают эффективности предлагаемого метода.

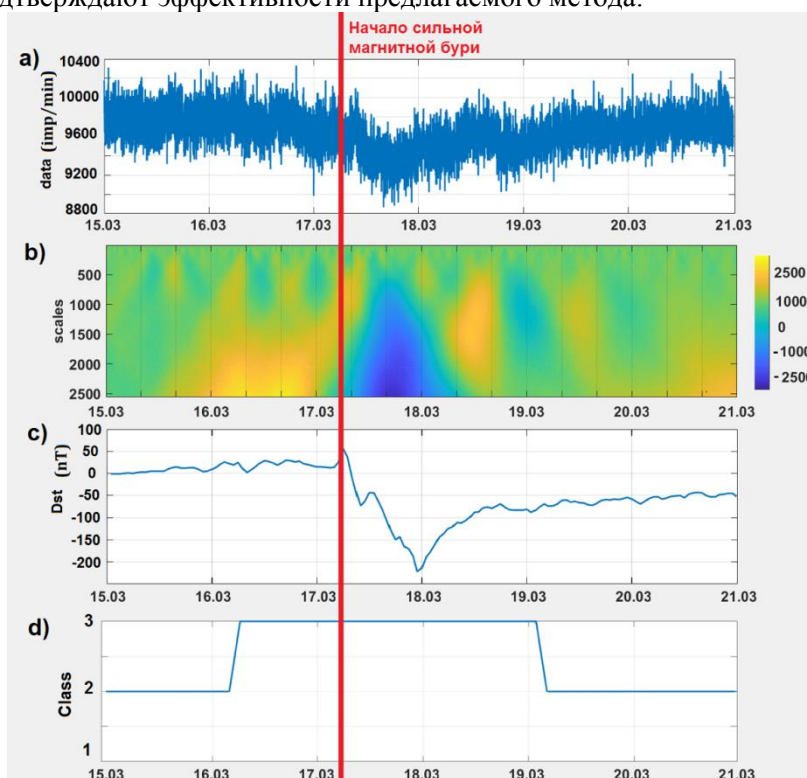


Рисунок 7. а) данные НМ (станция Kingston, [30]) за 15-20 марта 2015г., б) вейвлет-спектр данных НМ, с) данные Dst-индекса, б) результаты работы сети LVQ2_coif3_2.

5. Выводы

Применение нейронных сетей векторного квантования показало перспективность использования данного аппарата для анализа динамики космических лучей и обнаружения спорадических эффектов. Экспериментально подтверждена эффективность применения кратномасштабных вейвлет-разложений на этапе предобработки данных, поступающих на вход нейронной сети. Результаты подтвердили хорошие аппроксимирующие свойства вейвлет-функции Койфлет порядка 3. На примере событий 17 марта 2015 г. и 20-21 января 2016 г. показана возможность применения метода в задачах оперативного анализа данных нейтронных мониторов и выделения разномасштабных спорадических эффектов, в т.ч. малой амплитуды. Оценка работы построенных нейронных сетей показала их высокую результативность, погрешность решения сети LVQ2_coif3_2 составила менее 5%.

В будущем авторы планируют продолжить исследование по данному направлению с привлечением более широкого спектра станций регистрации данных космических лучей и увеличением статистического материала.

6. Литература

- [1] Dorman, L.I. Experimental Basis of Cosmic Ray Research, 2004. – P. 201-286. DOI: 10.1007/978-1-4020-2113-8_4.
- [2] Storini, M. Galactic cosmic-ray modulation and solar-terrestrial relationships // *NuovoCimSoc Ital Fis.* – 1990. – P. 13. DOI: 10.1007/BF02515780.
- [3] Forbush, S.E. On cosmic ray effects associated with magnetic storms // *Eos, Trans Am Geophys Union.* – 1938. – Vol. 19. – P. 193-194. DOI: 10.1029/TR019i001p00193-1.
- [4] Eroshenko, E.A. The alert signal of GLE of cosmic rays / E.A. Eroshenko, A.V. Belov, O.N. Kryakunova, V.G. Kurt, V.G. Yanke // *Proceedings of the 31st ICRC, 2009.*
- [5] Ni, S. Interplanetary coronal mass ejection induced forbush decrease event: a simulation study with one-dimensional stochastic differential method // *Zhiyi.* – 2017. – Vol. 63. – P. 1-8. DOI: 10.7498/aps.66.139601.
- [6] Mishev, A. Application of a full chain analysis using neutron monitor data for space weather studies / A. Mishev, I. Usoskin, 2016.
- [7] Vipindas, V. Periodicity analysis of galactic cosmic rays using Fourier, Hilbert, and higher-order spectral methods / V. Vipindas, S. Gopinath, T.E. Girish // *AstrophysSpaceSci.* – 2016. – Vol. 361. DOI: 10.1007/s10509-016-2719-y.
- [8] Livada, M. Galactic cosmic ray spectral index: the case of Forbush decreases of March / M. Livada, H. Mavromichalaki, C. Plainaki // *Astrophys Space Sci.* – 2018. – Vol. 363. – P. 8. DOI: 10.1007/s10509-017-3230-9.
- [9] Ni, S. Interplanetary coronal mass ejection induced forbush decrease event: a simulation study with one-dimensional stochastic differential method / S. Ni, B.H. Gu // *Zhiyi.* – 2017. – Vol. 63. – P. 1-8. DOI: 10.7498/aps.66.139601.
- [10] Belov, A.V. Cosmic ray anisotropy before and during the passage of major solar wind disturbances / A.V. Belov, J.W. Bieber, E.A. Eroshenko, P. Evenson, R. Pyle, V.G. Yanke // *Adv. Space Res.* – 2003. – Vol. 31(4). – P. 919-924.
- [11] База данных реального времени для измерений Нейтронного монитора высокого разрешения [Электронный ресурс]. – Режим доступа: www.nmdb.eu. (01.12.2018).
- [12] Агеев, А.Д. Нейроматематика: учеб. пособие для вузов. – М.: ИПРЖР, 2002. – 448 с.
- [13] Хайкин, С. Нейронные сети: полный курс. – М.: Издательский дом Вильямс, 2006. – 1104 с.
- [14] Spitsyn, V.G. Using a Haar wavelet transform, principal component analysis and neural networks for OCR in the presence of impulse noise / V.G. Spitsyn, Yu.A. Bolotova, N.H. Phan, T.T.T. Bui // *ComputerOptics.* – 2016. – Vol. 40(2). – P. 249-257. DOI: 10.18287/2412-6179-2016-40-2-249-257.
- [15] Izotov, P.Y. Technology of implementation of neural network algorithm in cuda environment at the example of handwritten digits recognition / P.Y. Izotov, S.V. Sukhanov, D.L. Golovashkin // *Computer Optics.* – 2010. – Vol. 34(2). – P. 243-251.
- [16] Мандрикова, О.В. Автоматический способ оценки состояния геомагнитного поля / О.В. Мандрикова, Е.А. Жижикина // *Компьютерная оптика.* – 2015. – Т. 39, № 3. – С. 420-428. DOI: 10.18287/0134-2452-2015-39-3-420-428.
- [17] Рудой, Г.И. Выбор функции активации при прогнозировании нейронными сетями // *Машинное обучение и анализ данных.* – 2011. – Т. 1, № 1. – С. 16-39.
- [18] Балдин, Н.П. Исследование сходимости при прогнозировании нейронными сетями с обратной связью // *Машинное обучение и анализ данных.* – 2011. – Т. 1, № 1. – С. 61-76.
- [19] Головкин, В.А. Нейронные сети: обучение, организация и применение. – М.: ИПРЖР, 2001.
- [20] Мандрикова, О.В. Моделирование вариаций космических лучей и выделение аномалий на основе совмещения вейвлет-преобразования с нейронными сетями / О.В. Мандрикова, Т.Л. Заляев // *Машинное обучение и анализ данных.* – 2014. – Т. 1, № 9. – С. 1154-1167.
- [21] Мандрикова, О.В. Анализ динамики космических лучей на основе нейронных сетей / О.В. Мандрикова, Т.Л. Заляев, Б.С. Мандрикова, М.С. Куприянов // *Международная конференция по мягким вычислениям и измерениям XXI, 2018 г.*

- [22] Mandrikova, O.V. Analysis of the dynamics of cosmic rays on the basis of neural networks / O.V. Mandrikova, T.L. Zalyaev, B.S. Mandrikova // Journal of Physics: Conference Series – 2018. – P. 112-118.
- [23] Chui, S.K. An introduction in wavelets. – Academic Press, New York, 1992. – 264 p.
- [24] Mallat, S. A wavelet tour of signal processing. – London: Academic Press, 1999. – P. 620.
- [25] Мандрикова, О.В. Аппроксимация и анализ ионосферных параметров на основе совмещения вейвлет-преобразования с коллективами нейронных сетей / О.В. Мандрикова, Ю.А. Полозов // Информационные технологии. – 2014. – № 7. – С. 61-65.
- [26] Daubechies, I. Ten Lectures on wavelets // CBMS–NSF lecture notes nr. – SIAM, Philadelphia, 1992.
- [27] Kohonen, T. Self-organizing maps. – Berlin; Heidelberg; New York; Barcelona; Hong Kong; London; Milan; Paris; Singapore; Tokyo: Springer, 2001. – 501 p.
- [28] Bertin, E. Voronoi pyramids controlled by Hopfield neural networks/ E. Bertin, H. Bischof, P. Bertolino // Comput. Vision Image Understand. – 1996. – Vol. 63(3). – P. 462-475.
- [29] Hammer, B. Generalized relevance learning vector quantization / B. Hammer, T. Villmann // Neural Networks. – 2002. – Vol. 15. – P. 1059-1068.
- [30] Архив данных нейтронных мониторов ИЗМИРАН станция Kingston [Электронный ресурс]. – Режим доступа: <http://cr0.izmiran.ru/kgsn/main.htm>. (01.12.2018).
- [31] Добеши, И. Десять лекций по вейвлетам. – Ижевск: НИЦ “Регулярная и хаотическая динамика”, 2001. – 463 с.
- [32] Архив данных Dst-индекса геомагнитной активности [Электронный ресурс]. – Режим доступа: <http://wdc.kugi.kyoto-u.ac.jp/dstdir/>. (01.12.2018).
- [33] Прогноз космической погоды по данным Института прикладной геофизики имени академика Е.К. Федорова [Электронный ресурс]. – Режим доступа: <http://ipg.geospace.ru>. (01.12.2018).

Method of cosmic ray data analysis based on neural networks of vector quantization

O.V. Mandrikova¹, V.V. Geppener², B.S. Mandrikova²

¹Institute of Cosmophysical Research and Radio Wave Propagation FEB RAS, Mirnaya str. 7, Paratunka, Kamchatka region, Russia, 684034

²The First Electrotechnical University, Professora Popova street 5, St. Petersburg, Russia, 197022

Abstract. The paper describes an automated method for analyzing cosmic ray data and detecting sporadic effects. The method is based on the application of multi-scale wavelet decompositions and neural networks of vector quantization. Using the method, the dynamics of cosmic rays was studied during the periods of increased solar activity and magnetic storms. Sporadic effects preceding and accompanying magnetic storms were detected. The paper shows the efficiency of the method for the mode of on-line data analysis and the detection of sporadic effects, including small amplitude. The results are important in the tasks of space weather forecast.