

УДК 519.72

АВТОМАТИЗИРОВАННЫЙ МЕТОД АНАЛИЗА ДАННЫХ КОСМИЧЕСКИХ ЛУЧЕЙ И ВЫДЕЛЕНИЯ СПОРАДИЧЕСКИХ ЭФФЕКТОВ¹⁾

© 2021 г. В. В. Геппенер^{1,*}, Б. С. Мандрикова^{2,**}

¹ 197022 Санкт-Петербург, ул. Профессора Попова, 5, СПбГЭТУ “ЛЭТИ”, Россия

² 684034 Камчатский край, Паратунка, Мирная ул., 7, ИКИР ДВО РАН, Россия

*e-mails: geppener@mail.ru

**e-mail: 555bs5@mail.ru

Поступила в редакцию 26.11.2020 г.
Переработанный вариант 26.11.2020 г.
Принята к публикации 11.03.2021 г.

Предложен автоматизированный метод обнаружения разномасштабных спорадических эффектов по данным наземных станций нейтронных мониторов. Метод включает использование конструкций кратномасштабного анализа и кластерных нейронных сетей типа Learning vector quantization. Обоснован выбор вейвлетов семейств Добеши и Койфлеты на этапе предобработки данных. Предложен алгоритм выбора “наилучшего” аппроксимирующего вейвлет-базиса в классе ортогональных функций. Эмпирическим путем подтверждена эффективность предлагаемого метода для обнаружения мелкомасштабных спорадических эффектов. Показана возможность численной реализации предлагаемого метода для применения в оперативном режиме. Библ. 34. Фиг. 5. Табл. 2.

Ключевые слова: метод анализа данных, нейронные сети LVQ, вейвлет-преобразование, космические лучи, спорадические эффекты.

DOI: 10.31857/S0044466921070061

1. ВВЕДЕНИЕ

Анализ космических лучей проводят при исследовании проблем солнечно-земной физики, а также в решении многих практических задач, связанных с космической погодой. Аномальные события, возникающие на Солнце, в околоземном космическом пространстве (ОКП) находят негативное отражение в работе техносферных систем, а также могут оказывать губительное воздействие на здоровье и жизнь людей [1]. В действительности до сих пор не существует решения, позволяющего получить оперативный и точный прогноз космической погоды [1]. Ключевым моментом в данной области исследования является создание автоматизированных методов анализа данных и своевременного обнаружения аномальных процессов в ОКП. В динамике потока космических лучей различают два типа возмущений – рекуррентные (характерные) вариации и спорадические (аномальные) изменения. Рекуррентные вариации определяются высокоскоростными потоками плазмы из корональных дыр на Солнце. Корональные выбросы (CMEs – coronal mass ejections) служат причиной возникновения спорадических событий в космических лучах. В потоке солнечного ветра корональные выбросы превращаются в межпланетные облака ICMEs. Спорадические эффекты, являющиеся предметом исследования, проявляются в виде форбуш-эффектов [2] и сильных протонных возрастаний Ground Level Enhancement (GLE-событий). Характеристики и параметры форбуш-эффектов определяются многими факторами, и их исследования важны для изучения процессов в ОКП и в задачах, связанных с прогнозом космической погоды. В современном представлении форбуш-эффект является гелиосферным явлением, включающим в себя аномальные понижения интенсивности потока космических лучей, восстановление характерной динамики, а также мелкомасштабные изменения плотности и ани-

¹⁾ Работа выполнена в рамках Государственного задания по теме “Физические процессы в системе ближнего космоса и геосфер в условиях солнечного и литосферного воздействий” (2021–2023 гг.), № гос. регистрации АААА-А21-121011290003-0.

зотропии космических лучей, возникающие перед началом крупного форбуш-понижения и служащие их предвестниками. Аномальные изменения в межпланетном пространстве и в потоке космических лучей способны вызвать отклик в магнитосфере и ионосфере Земли. GLE-события опасны сильным радиационным излучением и подвергают риску здоровье и жизнь людей [1]. Потоки космических лучей изотропно со всех направлений космического пространства достигают Земли. Попадая в атмосферу, они вступают в реакцию с содержащимися в воздухе атомами азота и кислорода [3]. Результатом реакции становятся расщепление ядер атомов и появление нестабильных элементарных частиц. Данные частицы, регистрируемые в атмосфере, называются вторичными космическими лучами.

Регистрацию и изучение временного ряда данных космических лучей проводят по измерениям сети нейтронных мониторов [4]. Сигнал космических лучей имеет сложную нестационарную структуру, и включает множество различных аномальных эффектов. Регистрируемые вторичные космические лучи содержат высокий уровень шума и зависят от метеорологических факторов и атмосферных явлений, географических координат станции, а также электромагнитной обстановки в Солнечной системе и физических условий в Галактике [5]. Неполные знания о процессах в ОКП существенно затрудняют этап построения методов и моделей анализа данных нейтронных мониторов. Традиционные классические подходы и методы (спектральные методы [7], [8], сглаживающие и регрессионные методы [6], [9]) направлены на изучение устойчивых свойств и характеристик данных, но не являются эффективными для исследования нестационарных аномальных изменений в динамике потока космических лучей. Поскольку мелкомасштабные форбуш-эффекты имеют малый носитель и небольшую амплитуду, их детектирование в шуме является весьма сложной задачей [10]. Современный метод кольца станций дает возможность вычислять характеристики и параметры временного ряда космических лучей с достаточной точностью. Но точность данного метода сильно зависит от плотности станций регистрации, а также ввиду сложных математических расчетов его автоматизация до настоящего момента не реализована. В работе, с целью преодоления описанных проблем и с учетом не изученности явлений, протекающих в ОКП, предложено использовать аппарат искусственных нейронных сетей (ИНС). Аппарат ИНС нашел широкое применение в задачах экстраполяции сложных функций и подтвердил свою эффективность в случае отсутствия полных априорных знаний об исследуемых процессах и их взаимодействиях [11], [13]. Также известным преимуществом ИНС является численная реализация нейросетевых парадигм, обеспечивающая их автоматизацию [14], [15]. Ввиду указанных преимуществ аппарата нейронных сетей, он широко используется для решения геофизических задач [12], [13]. Предлагаемый в статье подход впервые рассмотрен в работе [17], он основан на использовании конструкции ортогонального кратномасштабного анализа (КМА [18], [19]) и кластерных нейронных сетей Learning vector quantization (LVQ [29]). В работах [20]–[23] показано, что объединение аппаратов вейвлет-преобразования и нейронных сетей повышает успешность распознавания образов и аппроксимации сложных функций [23], [24]. Для использования комбинации указанных методов в работе определены и обоснованы применяемые семейства ортогональных вейвлетов. Предложен алгоритм выбора “наилучшего” аппроксимирующего вейвлет-базиса в классе ортогональных функций. Эмпирически подтверждена эффективность предлагаемого метода для обнаружения мелкомасштабных спорадических эффектов.

2. ОПИСАНИЕ МЕТОДА

2.1. Применение кратномасштабных ортогональных вейвлет-разложений


Будем рассматривать пространство, порожаемое сдвигами и растяжениями скейлинг-функции ϕ [18], [19]:

$$V_j = \text{clos}_{L(R)}^2(\phi(2^j t - n)),$$


где $n \in Z$, $L^2(R)$ – пространство Лебега. Тогда, на основе отображения функции f_j в подпространства V_{j-1} и W_{j-1} (пространство W_{j-1} порождается сдвигами и растяжениями вейвлета

$\Psi_{j-1,n} = 2^{-\frac{j-1}{2}} \Psi(2^{j-1}t - n)$) получим ее представление в виде

$$f^j(t) = g^{j-1}(t) + f^{j-1}(t) = \sum_n d_{j-1,n} \Psi_{j-1,n}(t) + \sum_n c_{j-1,n} \phi_{j-1,n}(t). \quad (2.1)$$



Фиг. 1. Данные НМ ст. “Новосибирск” за 3 августа 2019 г.: черная кривая – первичные данные НМ; желтая кривая – данные с предобработкой (ф. Койфлет 3, разложение до уровня $m = 1$), красная кривая – данные с предобработкой (ф. Койфлет 3, разложение до уровня $m = 2$).



Фиг. 2. АЧХ функций вейвлет Ψ и масштабирующей ϕ : черный график – на первом уровне разложения; красный график – на втором уровне разложения (использовался вейвлет Койфлет 3).

Применяя рекурсивно операцию (2.1) m раз, получаем

$$f^j(t) = g^{j-1}(t) + g^{j-2}(t) + \dots + g^{j-m}(t) + f^{j-m}(t) = \sum_{k=j-1}^{j-m} \sum_n d_{k,n} \Psi_{k,n}(t) + \sum_n c_{j-m,n} \phi_{j-m,n}(t). \quad (2.2)$$

Составляющие в представлении (2.2) определяются как $c_j = \{c_{j,n}\}_{n \in Z} \in V_j$ и $d_j = \{d_{j,n}\}_{n \in Z} \in W_j$, вейвлет-коэффициенты $c_{j,n} = \langle f, \phi_{j,n} \rangle$, $d_{j,n} = \langle f, \Psi_{j,n} \rangle$. Составляющие g^{j-1} являются детализирующими (высокочастотными), а составляющая f^{j-m} сглаженной [18], [26].

На фиг. 1 показан результат представления временного ряда данных нейтронного монитора (НМ) станции Новосибирск в виде (2.2) для уровней вейвлет-разложения $m = 1, 2$. Анализ результатов показывает наличие во временном ряде данных НМ высокого уровня шума и подтверждает эффективность применения операций КМА для его подавления. В работе, следуя результатам [17], использовалось кратномасштабное представление данных НМ для $m = 1$. Оценки в работе [17] показали возрастание погрешности работы сети начиная с уровня вейвлет-разложения $m = 2$. Данный результат свидетельствует о наличии полезной информации в составляющей 2-го уровня вейвлет-разложения. Анализ амплитудно-частотных характеристик (АЧХ) вейвлета и масштабирующей функции (см. фиг. 2) показывает, что на 2-м уровне вейвлет-разложения детектируются колебания в диапазоне 3–14 мин.

2.2. Определение вейвлет-функции и построение “наилучшего” аппроксимирующего базиса

В работе рассматривались библиотеки ортогональных вейвлет-функций, которые позволяют получить численной устойчивости разложения вида (2.2). Определение вейвлет-функции базисировалось на следующих критериях, впервые рассмотренных в работе [25].

1. Вейвлет должен иметь большое число нулевых моментов. Число нулевых моментов вейвлета, т.е.

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

определяет его способность детектировать особенности функции вида $\alpha \leq s$, где α – порядок гладкости.

2. Вейвлет должен иметь малый носитель. Применение операций (2.1), (2.2) порождает возникновение “краевых эффектов” [19]. Величина краевого эффекта определяется по формуле $h_j = 2^j q$, где q – размер носителя вейвлета.

3. Вейвлет должен иметь высокий порядок гладкости α . Данное свойство вейвлета определяет его способность детектировать особенности высокого порядка – вида $\alpha \leq s$.

Опираясь на критерии 1–3, необходимо учитывать, что возрастание числа нулевых моментов неизбежно приводит к возрастанию величины носителя функции [19]. Также важным моментом является возможность получить наилучшее приближение функции в составляющей f^{j-m} (см. (2.2)), которое обеспечивается масштабирующей функцией ϕ с большим числом нулевых моментов. Учитывая данные аспекты и опираясь на критерии 1–3, в работе определены семейства вейвлетов Добеши и Койфлеты. Вейвлеты Добеши являются единственным семейством ортогональных вейвлетов, которые имеют наименьший носитель при заданном числе нулевых моментов [27]. Койфлеты – это единственное семейство ортогональных вейвлетов, имеющих наименьший носитель при достаточном числе нулевых моментов в масштабирующей функции ϕ [26]. Для Койфлетов также выполняется следующее важное свойство (см. [26]).

Для любой $f \in C^r$ (C^r пространство r раз непрерывно дифференцируемых функций) в окрестности $2^{-m}n$ при $r \leq s$ выполняется условие

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

Порядок приближения возрастает с ростом s , Койфлет при этом имеет носитель $3s - 1$.

Построение “наилучшего” аппроксимирующего базиса в работе основывалось на минимаксном подходе [28], следуя которому погрешность получаемой оценки \tilde{F} определяется в виде

$$(D, F) = \mathbf{E} \{ \|F - Df\|^2 \},$$

где F – оцениваемый сигнал, f – зашумленные данные, D – оператор решения, \mathbf{E} – математическое ожидание $\|\cdot\|$ – норма. Минимаксный риск – это нижняя граница, вычисленная по всем операторам D [28]:

$$r(\Theta) = \inf_D \sup_{y \in \Theta} \mathbf{E} \{ \|F - Df\|^2 \}.$$

Рассматривая в качестве оператора D преобразования (2.1), (2.2) и следуя работе [19], оценка \tilde{F}^λ в базисе β^λ может быть получена в виде

$$\tilde{F}^\lambda = \sum_n P_T (\langle f, \beta_n^\lambda \rangle) \beta_n^\lambda,$$

где P_T – пороговая функция. Тогда наилучший базис β^λ – есть базис, который минимизирует погрешность

$$\mathbf{E} \left\{ \|F - \tilde{F}^\alpha\|^2 \right\} = \min_{\lambda \in \Lambda} \mathbf{E} \left\{ \|F - \tilde{F}^\lambda\|^2 \right\}.$$

В этом случае определение “наилучшего” базиса может быть основано на выполнении следующих операций.

Шаг 1. На основе отображения (2.2) выполняем преобразование функции f :

$$f^j(t) = g^{j-1}(t) + g^{j-2}(t) + \dots + g^{j-m}(t) + f^{j-m}(t) = \sum_{k=j-1}^{j-m} \sum_n d_{k,n} \Psi_{k,n}(t) + \sum_n c_{j-m,n} \phi_{j-m,n}(t).$$

Шаг 2. Путем применения пороговых функций P_{T_j} (см. (2)) получаем оценку

$$\tilde{F}^m = \sum_{k=j-1, j-m} \sum_n P_{T_j}(d_{k,n}) \Psi_{k,n} + \sum_n P_{T_{j-m}}(c_{j-m,n}) \Phi_{j-m,n},$$

где $T_j = \text{Med}(\langle f, \beta^\lambda \rangle)$, $\beta^\lambda = \{\Psi_{k,n}, \Phi_{j-m,n}\}_{k=j-1, \dots, j-m}$, Med – медиана.

Шаг 3. Оцениваем величину

$$Q_m^\lambda = \sum_{n \in I_m^j} |c_{j-m,n}|^2 + \sum_{k=j-1, j-m} \sum_{n \in I^j} |d_{k,n}|^2,$$

где множество индексов I^j : $n \in I^j$, если $\langle f, \beta^\lambda \rangle \geq T_j$, и определяем “наилучший” базис β_m^α : $Q_m^\alpha = \max_{\lambda \in \Lambda} E\{Q_m^\lambda\}$.

2.3. Принцип работы кластерной нейронной сети типа Learning vector quantization и схема решения задачи

Предлагаемый метод основан на применении кластерных нейронных сетей типа Learning Vector Quantization (LVQ) [29], [30]. Построение LVQ-сети включает определение числа кластеров l (количество нейронов в первом слое) и числа классов k (количество нейронов во втором слое), а также определение принадлежности каждого кластера классу [27]:

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

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

В соответствии с решаемой задачей логично определить следующие $L = 3$ класса нейронной сети.

1. “Спокойный” класс – отсутствие спорадических эффектов. Признаками класса являются: (1) отсутствием активных пятен и вспышек на Солнце; (2) отсутствием потока солнечного ветра с видимой стороны по линии с Землей; (3) спокойная геомагнитная обстановка.

2. “Слабовозмущенный” класс – наличие мелкомасштабных спорадических эффектов. Признаками класса являются: (1) незначительные вспышки на Солнце, направленные на Землю; (2) слабые возмущения в магнитосфере.

3. “Возмущенный” класс – наличие крупномасштабных спорадических эффектов и/или GLE-событий. Признаками класса являются: (1) проникновением в окрестности Земли высокоскоростных потоков солнечного ветра и/или связанной с ним ударной волны; (2) сильные возмущения в магнитосфере.

Число кластеров сети определялось путем минимизации апостериорного риска и принято равным 20.

Кластеризация входных данных LVQ-сети базируется на применении метода наименьших квадратов:

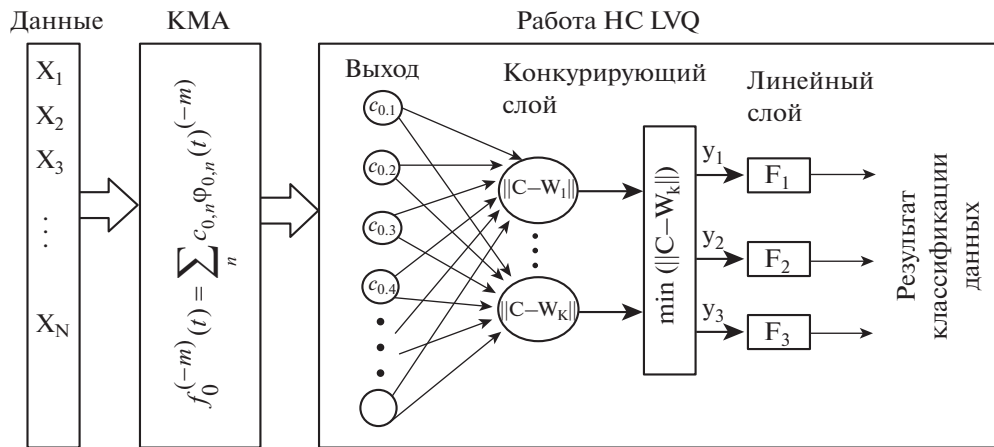
$$d_k = d(C, W_k) = \|C - W_k\| = \sqrt{\sum_{i=1}^l (c_i - w_{ik})^2},$$

где C – входной вектор; W_k – вектор весов нейрона k первого слоя сети, l – размерность входного вектора сети. В процессе работы сети в первом ее слое путем оценки расстояния d_k определяется нейрон-победитель p :

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

В процессе функционирования сети один элемент выходного вектора равен 1, остальные – нулю. Таким образом, сеть решает задачу классификации.

В соответствии с предлагаемым подходом, решение задачи классификации данных нейронных мониторов может быть представлено в виде схемы, показанной на фиг. 3. Для восстановления исходного разрешения функции выполняется операция вейвлет-восстановления:



Фиг. 3. Общая схема решения задачи.

$f_0^{(-m)}(t) = \sum_n c_{0,n} \varphi_{0,n}(t)^{(-m)}$, (верхний индекс $(-m)$ соответствует разрешению функции до выполнения операции вейвлет-восстановления).

Для оценки метода использовались минутные данные наземных станций нейтронных мониторов [32]. Определение классов нейронных сетей основывалось на анализе геомагнитных индексов – A , K и Dst индексы [33]. “Спокойный” класс формировался из данных за периоды, в которые A -индекс был менее 7, K -индекс был менее 3, Dst -индекс находился в пределах ± 4 . “Слабовозмущенный” класс (наличие мелкомасштабных спорадических эффектов) формировался из данных за периоды, в которые A -индекс был менее 18, K -индекс был менее 5, Dst -индекс находился в пределах ± 8 . “Возмущенный” класс (наличие крупномасштабных спорадических эффектов и/или GLE-событий) включал периоды, в которые A -индекс был менее 18, K -индекс был больше 4, Dst -индекс превышал ± 8 . Для периодов высокой и низкой солнечной активности (солнечная активность определялась по значениям индексов $f_{10.7}$ [33]) сети обучались отдельно. В разложениях использовались вейвлет-функции семейств Добеши и Койфлеты (выбор семейств обоснован в п. 2.2). Входные векторы сети, следуя работе [17], имели длительность, равную трем суткам. Разложения (2.2) выполнялись для $m = 1$ [17], [34]. Перед подачей на вход сети выполнялось восстановление исходного разрешения функций на основе операции обратного вейвлет-преобразования. С целью уменьшения краевого эффекта выполнялось зеркальное дополнение функций. Оценки показали, что наименьшую погрешность сети позволяют получить вейвлеты Добеши 3-го порядка (db3) и Койфлеты 3-го порядка (coif3). Результаты оценок (см. табл. 1) подтвердили эффективность метода, включающего совместное использование кластерных нейронных сетей LVQ и процедуры ортогональных кратномасштабных вейвлет-разложений (представление (2.2)). Анализ результатов показал зависимость динамики космических

Таблица 1. Результаты работы построенных сетей

Входной сигнал сети		Первичные данные НМ	db3_1	coif3_1
Работа сети LVQ1 (данные за период высокой солнечной активности)	“Спокойный” класс	100%	100%	100%
	“Слабовозмущенный” класс	80%	87%	93%
	“Возмущенный” класс	93%	93%	93%
Работа сети LVQ2 (данные за период низкой солнечной активности)	“Спокойный” класс	73%	–	80%
	“Слабовозмущенный” класс	75%	–	75%
	“Возмущенный” класс	67%	–	83%

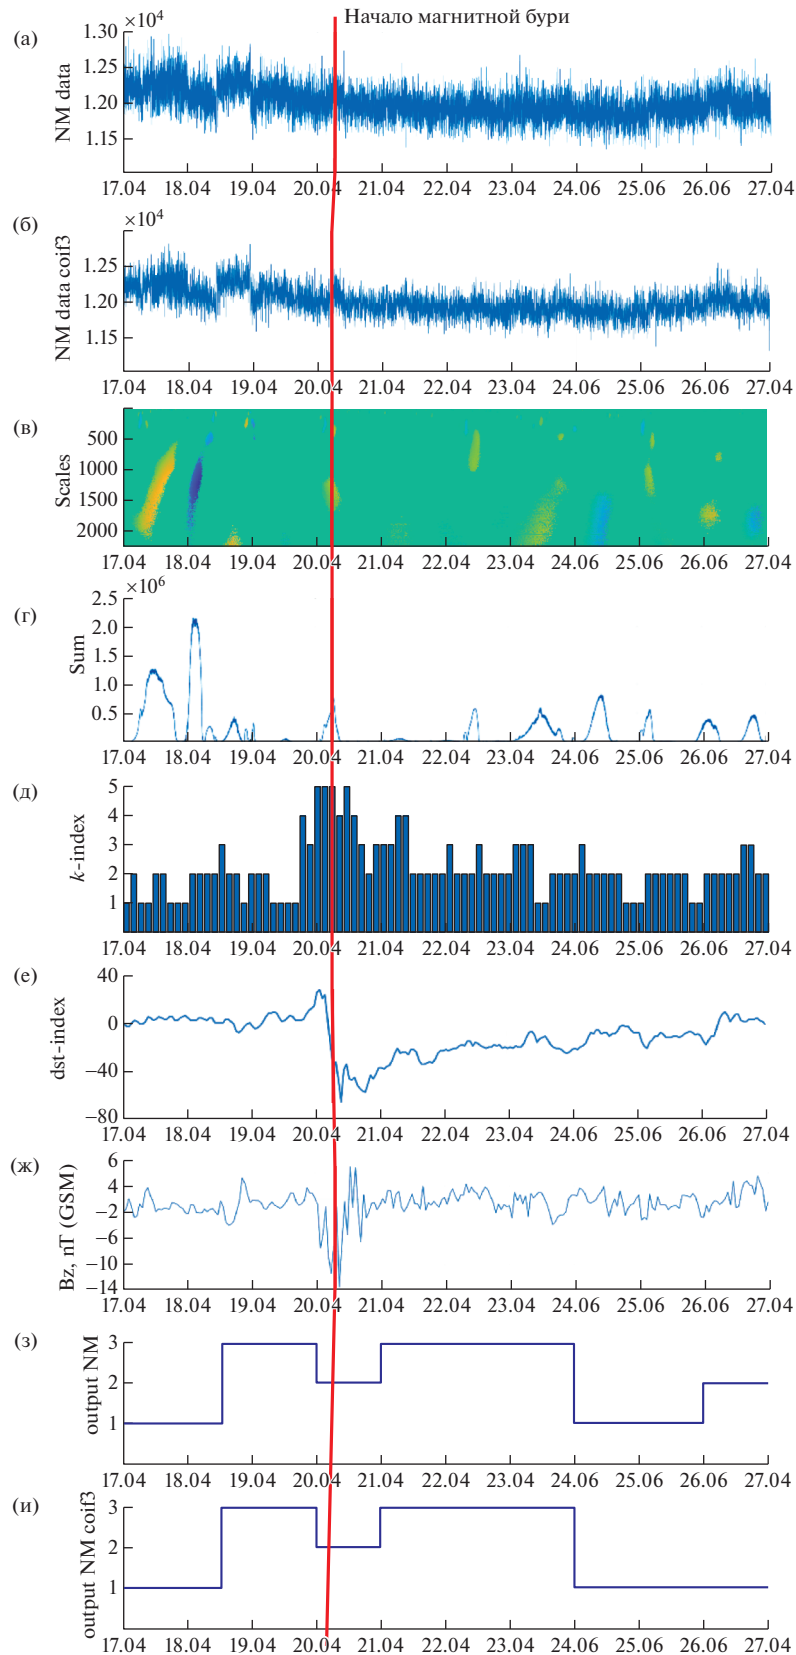
лучей от уровня солнечной активности. В период высокой солнечной активности погрешность метода не превышала 7%. В период низкой солнечной активности погрешность возросла до 21%. Поскольку мерой возмущенности потока ГКЛ является величина отклонения вариаций от характерного уровня [16], очевидно, в периоды низкой солнечной активности шкалы амплитуд вариаций имеют меньший размах. Для повышения эффективности метода в период низкой солнечной активности, вероятно, требуется увеличить размер обучающей выборки. Также повысить эффективность метода, возможно, позволит увеличение числа анализируемых станций.

3. РЕЗУЛЬТАТЫ ПРИМЕНЕНИЯ МЕТОДА

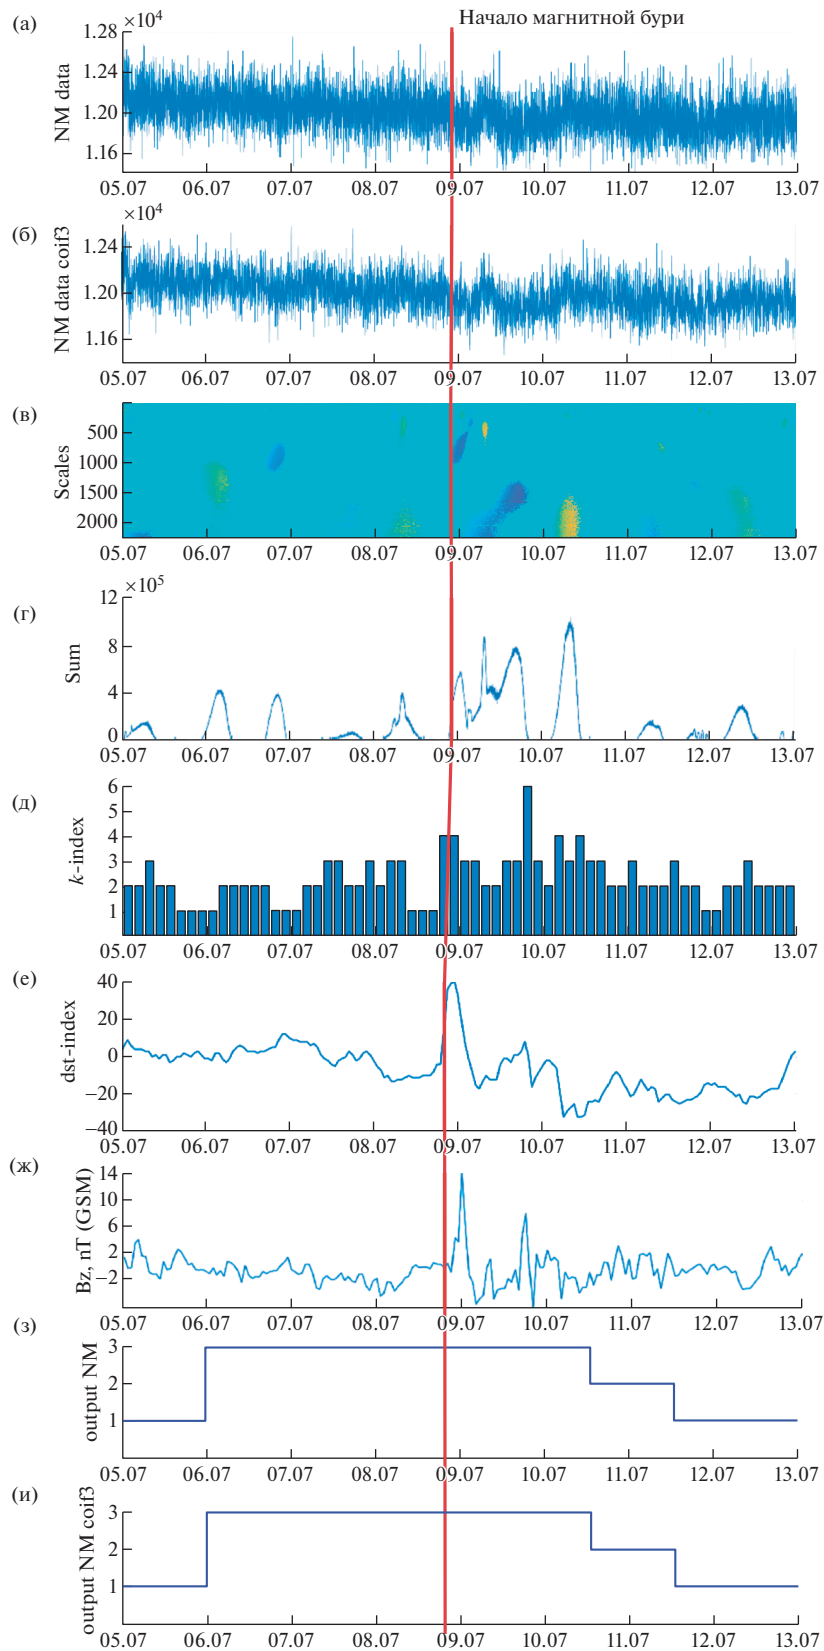
Результаты применения метода показаны на фиг. 4 и 5. Магнитная буря 20 апреля 2018 г. (фиг. 4) вызвана неоднородным скоростным потоком из корональной дыры [31]. Накануне события 17–19 апреля скорость солнечного ветра (ССВ) была в окрестности 300 км/с, флуктуации компоненты межпланетного магнитного поля (ММП) составляли $B_z = \pm 5$ нТ (фиг. 4ж, [31]). Неоднородный ускоренный поток от корональной дыры (CIR) пришел в конце суток 19 апреля, 20 апреля флуктуации компоненты ММП усилились до $B_z = \pm 19$ нТ, ССВ возросла до 650 км/с и оставалась в этих пределах до конца суток 21 апреля. Далее, с 22 апреля в связи с ослаблением влияния корональной дыры, ССВ уменьшилась до 350 км/с, флуктуации ММП уменьшились до $B_z = \pm 5$ нТ. Результаты обработки данных показывают накануне события 18 апреля возникновение крупномасштабных аномальных изменений в динамике космических лучей (см. фиг. 4з, и). Отметим, что момент возникновения форбуш-эффекта совпадает с моментом увеличения размаха флуктуаций ММП, и в этот период наблюдается возрастание К-индекса. Аномальные изменения в данных нейтронного монитора 18 апреля также показывают результаты применения пороговых функций (фиг. 4в, г, алгоритм описан в Приложении). За несколько часов до события амплитуда форбуш-эффекта значительно увеличилась, форбуш-понижение наблюдалось в начальную и основную фазы бури. Плавное восстановление уровня космических лучей произошло по данным обработки к началу суток 26 апреля (“слабовозмущенный” класс). Заметим, что в период мелкомасштабных аномальных изменений в динамике КЛ 21–26 апреля (результаты порогового алгоритма, см. фиг. 4в, г) происходили повышения К-индекса (фиг. 4д). Сопоставление результатов работы сети с данными ОКП указывает на достоверность решений нейронной сети и подтверждает эффективность метода.

Результаты применения метода в период слабой магнитной бури 9 июля 2019 г. показаны на фиг. 5. По данным космической погоды [32] накануне события 05 июля ССВ возросла до 457 км/с. Около 18.30 UT 08 июля пришел неоднородный ускоренный поток от корональной дыры (CIR), ССВ к концу суток 08 июля возросла до 390 км/с, флуктуации компоненты ММП усилились до $B_z = \pm 8$ нТ. Во время магнитной ССВ достигла значения 695 км/с, размах флуктуаций ММП увеличился до $B_z = \pm 11$ нТ. В конце периода 11–13 июля ССВ находилась в пределах $v = 400$ –500 км/с, размах флуктуаций компоненты ММП составлял от $B_z = \pm 4$ нТ до $B_z = \pm 6$ нТ. Результаты работы сети (фиг. 5з, и) показывают изменение состояния потока космических лучей с начала суток 06 июля (“возмущенный” класс) до 12:00 UT 10 июля. Результаты порогового алгоритма (фиг. 5в, г) соответствуют результатам работы сети и показывают возникновение разномасштабных аномальных изменений в динамике космических лучей, которые достигают максимальных значений в период события. С 12:00 UT 10 июля по 12:00 UT 11 июля сеть классифицировала как “Слабовозмущенный” (класс 2), в конце периода динамика потока космических лучей восстановилась (“Спокойный” класс). Сопоставление результатов нейронной сети с данными межпланетного пространства и результатами порогового алгоритма подтверждает их достоверность.

Анализ результатов применения метода в возмущенные периоды показывает высокую частоту возникновения спорадических эффектов в космических лучах в преддверии магнитных бурь (см. табл. 2). Для основных фаз магнитных бурь характерно возникновение форбуш-понижений, длительность которых по данным табл. 2 может составлять от нескольких часов до нескольких суток. В работах [17], [34] детально рассмотрены результаты метода в периоды высокой солнечной активности, которые также подтверждают его эффективность для обнаружения спорадических эффектов в динамике космических лучей.



Фиг. 4. (а) – сигнал НМ ст. Москва 2018 г., (б) – сигнал НМ с предобработкой ф. Койфлет 3, разложение до уровня $m = 1$, (в) – применение порогового алгоритма (см. Приложение), положительные аномалии изображены желтым, отрицательные – синим, (г) – интенсивность аномальных изменений (см. Приложение), (д) – k -индекс, (е) – Dst -индекс, (ж) – B_z компонента ММП, (з) – работа НС LVQ, (и) – работа НС LVQ2_coif3_1.



Фиг. 5. (а) – сигнал НМ ст. Новосибирск 2019 г., (б) – сигнал НМ с предобработкой ф. Койфлет 3, разложение до уровня $m = 1$, (в) – применение порогового алгоритма (см. Приложение), положительные аномалии изображены желтым, отрицательные – синим, (г) – интенсивность аномальных изменений (см. Приложение), (д) – k -индекс, (е) – Dst -индекс, (ж) – B_z компонента ММП, (з) – работа НС LVQ, (и) – работа НС LVQ2_coef3_1.

Таблица 2. Результаты применения метода в возмущенные периоды

Анализируемые аномальные события (периоды, станция)	Выявленные аномалии накануне события (класс/время до бури)	Основной период события (класс)	Период восстановления (класс)
10.07.13–16.07.13 Кингстон	2/24 ч 3/12 ч	3	2
15.03.15–20.03.15 Кингстон	2/48 ч 3/12 ч	3	2
16.01.16–22.01.16 Кингстон	2/24 ч	3	2
21.08.18–28.08.18 Москва	2/18 ч	3	2
12.03.18–19.03.18 Москва	2/48 ч 3/24 ч	3	2
17.04.18–26.04.18 Москва	3/24 ч	3	1
17.04.18–26.04.18 Новосибирск	3/24 ч	3	1
4.10.18–11.10.18 Москва	2/68 ч 3/9 ч	3	2
5.07.19–12.07.19 Москва	2/68 ч 3/12 ч	3	1
5.07.19–12.07.19 Новосибирск	3/68 ч	3	1
4.06.19–11.06.19 Москва	2/9 ч	2	1
11.04.14–16.04.14 Инувик	3/12 ч	3	2
11.04.14–16.04.14 Thul	3/32 ч	3	1
12.09.14–16.09.14 Thul	3/24 ч	3	2
12.09.14–16.09.14 Инувик	2/60 ч	3	2
11.04.14–16.04.14 Москва	2/48 ч	3	1
12.09.14–16.09.14 Южный полюс	2/24 ч	3	1
5.09.14–7.09.14 Инувик	2/24 ч	3	2
10.09.14–13.09.14 Инувик	2/24 ч	3	2
29.08.17–01.09.17 Моусон	2/27 ч	2	2
5.09.17–09.09.17 Моусон	3/48 ч	3	3

4. ВЫВОДЫ

Предложенный в работе метод анализа данных космических лучей подтвердил свою эффективность в задачах обнаружения разномасштабных спорадических эффектов в динамике космических лучей. Эмпирически доказана результативность совместного применения конструкции ортогонального кратномасштабного анализа с кластерными нейронными сетями векторного квантования. Предложен алгоритм определения “наилучшего” аппроксимирующего вейвлет-базиса в классе ортогональных функций, основанный на минимаксном подходе. Подтверждена применимость метода для детектирования мелкомасштабных спорадических эффектов.

Результаты оценки метода показали его высокую результативность в период высокой солнечной активности – погрешность метода составила 7%. В период низкой солнечной активности флуктуации космических лучей имеют меньший размах, что усложняет задачу детектирования аномальных особенностей и, как следствие, погрешность метода возрастает (по результатам исследования до 21%). На примере магнитных бурь 2018–2019 гг. по измерениям данных разных станций показана возможность применения метода в оперативном режиме.

В будущем авторы планируют продолжить исследование в направлении расширения спектра анализируемых станций регистрации данных космических лучей и увеличения статистического материала.

Алгоритм выделения аномалий в динамике космических лучей и оценки их интенсивности [16], [22].

Шаг 1. Выполнение непрерывного вейвлет-преобразования:

$$(W_{\Psi}f_{b,s}) := |s|^{-1/2} \int_{-\infty}^{+\infty} f(t)\Psi\left(\frac{t-b}{s}\right)dt, \quad f \in L^2(R), \quad s, b \in R, \quad s \neq 0.$$

Шаг 2. Применение пороговой функции P_{T_s} :

$$P_{T_s}(W_{\Psi}f_{b,s}) = \begin{cases} W_{\Psi}f_{b,s}, & \text{если } (W_{\Psi}f_{b,s} - W_{\Psi}f_{b,s}^{\text{med},l}) \geq T_s^l, \\ 0, & \text{если } |W_{\Psi}f_{b,s} - W_{\Psi}f_{b,s}^{\text{med},l}| < T_s^l, \\ -W_{\Psi}f_{b,s}, & \text{если } (W_{\Psi}f_{b,s} - W_{\Psi}f_{b,s}^{\text{med},l}) < -T_s^l, \end{cases}$$

где $W_{\Psi}f_{b,s}^{\text{med},l}$ – медианное значение, рассчитанное в скользящем временном окне длины l , $T_s^l = U\sigma_s^l$ – порог,

$$\sigma_s^l = \sqrt{\left(\frac{1}{l} - 1 \sum_{k=1}^l (W_{\Psi}f_{b,s} - \overline{W_{\Psi}f_{b,s}})\right)^2}$$

есть стандартное отклонение, рассчитанное в скользящем временном окне длины l , $W_{\Psi}f_{b,s}$ – среднее значение, U – пороговый коэффициент.

Шаг 3. Оценка интенсивности аномалий: $\text{sum}(t) = \sum_s P_{T_s}(W_{\Psi}f_{b,s})$, которая в случае локального повышения КЛ будет положительной, а в случае локального понижения – отрицательной.

Авторы выражают благодарность институтам, выполняющим поддержку станций нейронных мониторов, которые использовались в работе.

СПИСОК ЛИТЕРАТУРЫ

1. *Eroshenko E.A., Belov A.V., Kryakunova O.N., Kurt V.G., Yanke V.G.* The alert signal of GLE of cosmic rays // In proceedings of the 31st ICRC. 2009.
2. *Forbush S.E.* On cosmic ray effects associated with magnetic storms // *Eos, Trans Am Geophys Union.* 1938. V. 19. P. 193–193. <https://doi.org/10.1029/TR019i001p00193-1>
3. *Топтыгин И.Н.* Космические лучи в межпланетных магнитных полях М.: Наука, 1938. 304 с.
4. Real time data base for the measurements of high-resolution Neutron Monitor. [Электронный ресурс] – Режим доступа: www.nmdb.eu (01.11.2019).
5. *Баренбаум А.А.* Галактика, Солнечная система, Земля. Соподчиненные процессы и эволюция. М.: ГЕОС, 2002. 394 с.
6. *Mishev A., Usoskin I.* Application of a full chain analysis using neutron monitor data for space weather studies // 25th European Cosmic Ray Symposium (ECRS 2016), Turin, Italy, September 04–09, 2016.
7. *Vipindas V., Gopinath S., Girish T.E.* Periodicity analysis of galactic cosmic rays using Fourier, Hilbert, and higher-order spectral methods // *Astrophys Space Science.* 2016. V. 361. 18 p. <https://doi.org/10.1007/s10509-016-2719-y>
8. *Livada M., Mavromichalaki H., Plainaki C.* Galactic cosmic ray spectral index: the case of Forbush decreases of March 2012 // *Astrophys. Space Science.* 2018. V. 363. P. 8. <https://doi.org/10.1007/s10509-017-3230-9>
9. *Ni Sulan, Gu B.H., Zhiyi.* Interplanetary coronal mass ejection induced forbush decrease event: simulation study with one-dimensional stochastic differential method. 2017. V. 63. P. 1–8. <https://doi.org/10.7498/aps.66.139601>
10. *Kota J., Jokipii J.R.* The role of corotating interaction regions in cosmic-ray modulation // *Geophys. Res. Lett.* 1991. V. 18. P. 1797–1800.
11. *Belov A.V. et al.* 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. V. 31. № 4. P. 919–924.

12. *Shimelevich M.I., Osborne E.A.* Application of the neural network method for approximating inverse operators in electromagnetic sounding problems // *Izv. Universities Geology and exploration*. 1999. № 2. P. 102–106.
13. *Baldin N.P.* Investigation of forecasting convergence by neural networks with feed-back // *Machine learning and data analysis*. 2011. V. 1. № 1. P. 61–76.
14. *Golovko V.A.* Neural networks: training, organization and application. Moscow: IPRZhR, 2001.
15. *Mandrikova O.V., Polozov Yu.A., Solovev I.S., Fetisova (Glushkova) N.V., Zalyaev T.L., Kupriyanov M.S., Dmitriev A.V.* Methods of Analysis of Geophysical Data during Increased Solar Activity // *Pattern recognition and image analysis (advances in mathematical theory and applications)*. 2016. V. 26. № 2, P. 406–418.
<https://doi.org/10.1134/S1054661816020103>
16. *Mandrikova O.V. et al.* Analysis of the Cosmic Rays dynamics on the basis of Neural Networks / O.V. Mandrikova, T.L. Zalyaev, B.S. Mandrikova, M.S. Kupriyanov // *Proceedings of 2018 21th IEEE International Conference on Soft Computing and Measurements (SCM 2018)*. 2018. V. 361. P. 683–686.
17. *Mandrikova O.V., Geppener V.V., Mandrikova B.S.* Method of analysis of cosmic ray data based 363 on neural networks of LVQ // *J. Physics: Conference Series (JPCS)*. 2019. V. 1374.
<https://doi.org/10.1088/1742-6596/1368/5/052026>
18. *Chui C.K.* An introduction in wavelets. New York: Academic Press, 1992. P. 264.
19. *Mallat S.* A wavelet tour of signal processing. London: Academic Press, 1999. P. 620.
20. *Mandrikova O.V., Zhizhikina E.A.* Automatic method for estimation of geomagnetic field state // *Computer Optics. Number Special*. 2016. V. 39. № 3. P. 420–428.
21. *Mandrikova O.V., Solovev I.S., Zalyaev T.L.* Methods of analysis of geomagnetic field variations and cosmic ray data // *Earth Planet Space*. 2014. V. 66.
<https://doi.org/10.3711186/s40623-014-0148-0>
22. *Mandrikova O., Polozov Yu., Fetisova N., Zalyaev T.* Analysis of the dynamics of ionospheric parameters during periods of increased solar activity and magnetic storms // *Journal of Atmospheric and Solar-Terrestrial Physics*. 2018. V. 181. P. 116–126.
<https://doi.org/10.1016/j.jastp.2018.10.019>
23. *Mandrikova O., Polozov Yu., Geppener V.* Method of ionospheric data analysis based on a combination of wavelet transform and neural networks // *Procedia Engineering*. 2017. V. 201. P. 756–766.
<https://doi.org/10.1016/j.proeng.2017.09.622>
24. *Burikov S.A., Efitorov A.O., Dolenko T.A., Shirokiy V.R., Dolenko S.A.* Solving inverse problems of Raman spectroscopy of aqueous salt solutions using wavelet-neural networks // *Siberian Journal of Physics*. 2018. V. 13. № 3. P. 101–109.
25. *Mandrikova O.V.* Approximation and Analysis of Ionospheric Parameters Based on a Combination of Wavelet Transformation and Neural Networks Groups / O.V. Mandrikova, Yu.A. Polozov // *Informatsionnye tekhnologii*. 2014. № 7. P. 61–65.
26. *Daubechies I.* Ten Lectures on wavelets. SIAM, Philadelphia. 1992.
27. *Hammer B., Villmann T.* Generalized relevance learning vector quantization // *Neural Networks*. 2002. V. 5. P. 1059–1068.
28. *Mertens J.-F., Neyman A.* Minimax Theorems for Undiscounted Stochastic Games // *Game Theory and Mathematical Economics*. 1981. P. 83–87.
29. *Kohonen T.* “Self-organizing maps”. 3 Ed. Tokyo: Springer, 2001. P. 501.
30. *Bertin E., Bischof H., Bertolino P.* Voronoi pyramids controlled by Hopfield neural networks // *Comput. Vision-Image Understand*. 1996. V. 63. № 3. P. 462–475.
31. Indices of geomagnetic activity [Электронный ресурс] – Режим доступа: <http://geobr.k.adm.yar.ru/database/indices/index?lang=ru> (11.11.2019).
32. Forecast of space weather according to the data of Federov Institute of Applied [Электронный ресурс] – Режим доступа: <http://ipg.geospace.ru> (01.12.2018).
33. NASA Interface to produce plots listings or output files from OMNI [Электронный ресурс] – Режим доступа: <https://omniweb.gsfc.nasa.gov/form/dx1.html> (11.11.2019).
34. *Mandrikova O.V., Polozov Yu.A., Mandrikova B.S.* Analysis of cosmic ray dynamics and ionospheric parameters during increased solar activity and magnetic storms, E3S Web of Conferences, 2019. V. 127.
<https://doi.org/10.1051/e3sconf/201912702002>