

УДК 519.65

МЕТОД ВЫДЕЛЕНИЯ АНОМАЛЬНЫХ ОСОБЕННОСТЕЙ В ДАННЫХ КРИТИЧЕСКОЙ ЧАСТОТЫ ИОНОСФЕРЫ НА ОСНОВЕ СОВМЕЩЕНИЯ ВЕЙВЛЕТ-ПРЕОБРАЗОВАНИЯ И НЕЙРОННЫХ СЕТЕЙ

Мандрикова О.В., д.т.н., ведущий научный сотрудник Института космических исследований и распространения радиоволн ДВО РАН; профессор Камчатского государственного технического университета, профессор кафедры систем управления, e-mail: ikir@ikir.ru

Полозов Ю.А., к.т.н., научный сотрудник Института космических исследований и распространения радиоволн ДВО РАН; доцент Камчатского государственного технического университета, доцент кафедры систем управления, e-mail: up_agent@mail.ru

Ключевые слова: вейвлет-преобразование, нейронные сети, критическая частота ионосферы, аномалии, землетрясения

Введение

Предметом исследований являются регистрируемые временные ряды ионосферных параметров, включающие в себя компоненты различной внутренней структуры и определяемые плотностью атмосферы, ее химическим составом и спектральными характеристиками солнечного излучения [1]. Исследование ионосферы выполняется дистанционными методами, одним из которых является вертикальное радиозондирование. Частота несущей радиоимпульса, для которой данная область ионосферы становится прозрачной, называется критической (f_oF2) и характеризует концентрацию электронов.

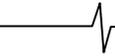
На фоне регулярных изменений, обусловленных суточным и сезонным ходом, в данных f_oF2 наблюдаются аномальные особенности длительностью от нескольких десятков минут до нескольких часов [2-8]. Эти аномалии имеют разнообразную структуру и возникают на фоне мощных ионосферных возмущений, которые обусловлены активностью Солнца в сейсмоактивных областях; они могут возникать в периоды повышения сейсмической активности [2-9]. Сложная структура ионосферных данных делает неэффективным для их анализа и выделения аномалий традиционные методы анализа временных рядов, которые основаны на процедуре сглаживания и приводят к потере важной информации [4]. Основные инструменты выделения аномалий основаны на анализе средних и медианных значений, что не позволяет выявить внутренние зависимости в данных и отдельные аномальные особенности.

Ввиду большого разнообразия базисных функций с компактными носителями, вейвлет-преобразование является эффективным инструментом анализа сложных временных рядов [2, 3, 11]. Используя конструкцию дискретного вейвлет-преобразования, в данной статье предложен алгоритм, позволяющий в автоматическом режиме в данных f_oF2 выделить аномальные особенности и определить их параметры. Для выделения и ана-

Предложен метод автоматического выделения аномальных особенностей, возникающих в регистрируемом временном ряде критической частоты ионосферы f_oF2 в периоды повышенной сейсмической или солнечной активности. Метод основан на совместном применении вейвлет-преобразования и нейронных сетей. На основе вейвлет-преобразования разработаны алгоритмы по обнаружению особенностей и оценке их параметров. Выделение и анализ характерных составляющих временного ряда выполняется на основе совместного применения вейвлет-преобразования с нейронными сетями. Апробация метода выполнена на данных f_oF2 , полученных на обсерватории «Паратунка» (с. Паратунка, Камчатский край).

лиза характерных составляющих временного ряда f_oF2 в работе предложен метод, основанный на совместном применении вейвлет-преобразования с нейронными сетями. Нейронные сети хорошо зарекомендовали себя при воспроизведении сложных нелинейных зависимостей [5, 13-15]. В работах [5, 10, 14, 15] показана эффективность применения этого аппарата для обработки и анализа ионосферных данных. Авторами этих работ предложены способы анализа и прогноза данных f_oF2 на основе нейронных сетей и показано, что результат их работы во многом определяется свойствами обучающего множества. В работах [14, 15] выполнен экспериментальный поиск подходящего обучающего множества и архитектуры нейронной сети. Если моделируемые данные являются сложными, зашумленными необходимо производить их предобработку и решать проблемы неинформативных и избыточных данных [4, 5, 10]. В работах [5, 10] для удаления неинформативных данных предложены способы совместного применения вейвлет-преобразования и нейронных сетей, разработаны алгоритмы формирования обучающего множества на основе вейвлет-фильтрации и показано, что данный подход позволяет оптимизировать процесс обучения сети и увеличить длину интервала упреждения данных. Настоящая работа является их продолжением, где на основе совместного применения конструкции вейвлет-пакетов и нейронных сетей разработан метод выделения и прогноза характерных компонент ряда f_oF2 .

В процессе апробации предложенного метода в данных f_oF2 выявлены аномальные особенности, возник-



кающие в периоды повышенной солнечной активности или обусловленные процессами в литосфере (анализировались сейсмические события энергетического класса с $k > 12$).

Выделение аномальных особенностей и определение их параметров на основе дискретного вейвлет-преобразования

Формально сложный временной ряд $f(t)$ может быть представлен в виде суммы разномасштабных компонент $f_j(t)$ с различной внутренней структурой [4]:

$$f(t) = \sum_j f_j(t), \text{ где } j - \text{ масштаб.}$$

Поскольку структура компонент f_j подвержена изменению в случайные моменты времени, наиболее эффективным способом для их описания является применение методов аппроксимации, основанных на разложении функции по базису. Учитывая локальный характер анализируемых особенностей, их разномасштабность и разнообразие по форме, наиболее подходящим пространством для их представления является вейвлет-пространство [4, 9, 11].

На основе *дискретного вейвлет-преобразования* для компонент f_j получаем следующее представление в виде вейвлет-схемы [11, 12]:

$$f_j(t) = \sum_n c_{j,n} \Psi_{j,n}(t), \quad (1)$$

где $\{\Psi_{j,n}\}_{(j,n) \in \mathbb{Z}^2}$ – ортонормированный базис пространства Лебега $L^2(\mathbb{R})$, $\Psi_{j,n} = 2^{j/2} \Psi(2^j t - n)$, $f_j \in L^2(\mathbb{R})$. Коэффициенты $\bar{c}_j = \{c_{j,n}\}_{n \in \mathbb{Z}}$ являются результатом отображения f в пространство с разрешением j , $c_{j,n} = \langle f, \Psi_{j,n} \rangle$.

Не нарушая общности, будем считать, что исходный дискретный временной ряд принадлежит пространству масштаба $j = 0$. Важность представления f в виде (1) состоит в том, что разномасштабные составляющие сложного временного ряда рассортировываются и хранятся в различных пространствах W_j с разрешением j :

$$W_{j=0} = \bigoplus_{j=-1}^{-J} W_j, \quad \{\Psi_{j,n}\}_{n \in \mathbb{Z}}$$

С целью возможности построения адаптивных аппроксимирующих вейвлет-схем, будем использовать *нелинейные отображения* [4, 9, 11]:

$$f_M(t) = \sum_{(j,n) \in I_M} c_{j,n} \Psi_{j,n}(t), \quad (2)$$

где f_M – проекция f на M векторов, индексы которых содержатся в некотором множестве I_M . В этом случае приближение функции f выполняется M векторами, зависящими от ее структуры.

Погрешность такой аппроксимации есть сумма оставшихся коэффициентов:

$$\varepsilon[M] = \|f - f_M\|^2 = \sum_{(j,n) \notin I_M} |c_{j,n}|^2.$$

Предполагая, что компонента $e(t) = \sum_{(j,n) \notin I_M} c_{j,n} \Psi_{j,n}(t)$ является следствием влияния шумового фактора, получаем представление в вейвлет-пространстве случайного временного ряда:

$$f(t) = \sum_{(j,n) \in I_M} c_{j,n} \Psi_{j,n}(t) + e(t).$$

Поскольку временной ряд включает характерные составляющие и аномальные особенности, представим его в следующем виде:

$$f(t) = \sum_{(j,n) \in I_A} a_{j,n} \Psi_{j,n}(t) + \sum_{(j,n) \in I_D} d_{j,n} \Psi_{j,n}(t) + e(t) = f_1(t) + f_2(t) + e(t), \quad (3)$$

$$\text{где } f_1(t) = \sum_{(j,n) \in I_A} a_{j,n} \Psi_{j,n}(t), \quad f_2(t) = \sum_{(j,n) \in I_D} d_{j,n} \Psi_{j,n}(t),$$

$\{a_{j,n}\}_{(j,n) \in I_A}$ – набор аппроксимирующих коэффициентов, описывающих характерные признаки данных, $\{d_{j,n}\}_{(j,n) \in I_D}$ – набор детализирующих коэффициентов, описывающих аномальные особенности, $I_A \cup I_D = I_M$.

В работах [9, 11, 12] показано, что отсутствие убывания амплитуды коэффициентов при $j \rightarrow 0$ характеризует наличие в $f(t)$ локальных особенностей, и операция их выделения может быть реализована на основе проверки условия:

$$|d_{j,n}| \geq T, \text{ при } j \rightarrow 0,$$

где T – некоторое пороговое значение. При этом наименьший анализируемый масштаб ограничен шагом выборки дискретного временного ряда.

Если вейвлет Ψ имеет компактный носитель, равный $[-C, C]$, то множество пар точек (j, n) таких, что некоторая точка V содержится в носителе $\Psi_{j,n}$, определяют конус влияния точки V масштабно-пространственной плоскости [11]. Так как носитель $\Psi_{j,n}$ на масштабе j равен $[n - C * 2^{-j}, n + C * 2^{-j}]$, то конус влияния точки V на масштабе j определяется неравенством

$$|n - v| \leq C * 2^{-j}, \quad j = -1, -2, \dots, -J.$$

Будем считать, что функция f в окрестности некоторой точки v имеет аномальную особенность масштаба j , если в окрестности точки v , размеры которой определяются конусом влияния, выполняется условие:

$$|d_{j,n}| \geq T_j, \quad (4)$$

где T_j – пороговое значение на масштабе j , временная длительность аномалии определяется конусом влияния точки v .

Операция выделения аномальных особенностей масштаба j может быть реализована на основе применения пороговых функций

$$P_{T_j}(x) = \begin{cases} x, & \text{если } |x| \geq T_j \\ 0, & \text{если } |x| < T_j \end{cases}$$

Выделенные таким способом *наборы детализирующих коэффициентов* $\{d_{j,n}\}_{(j,n) \in I_D}$ определяют компоненту $f_2(t)$ модели (3).

Интенсивность аномалии на масштабе j в окрестности точки v определим как $E_{f_{j,v}} = \max_n |d_{j,n}|$, где $n: |n-v| \leq d * 2^{-j}$.

Изменения интенсивности во времени можно проанализировать на основе величины

$$E_{f(t)} = \sum_j |d_{j,n}|. \quad (5)$$

Конструкция *вейвлет-пакетов* [11, 12] предполагает рекурсивное расщепление пространства W_j : $W_j = \oplus_{i=1}^l W_{j_i}^{p_i}$. Пространство $W_{j_i}^{p_i}$ допускает ортонормированный базис $\Psi_{j_i}^{p_i} = \{2^{j_i/2} \Psi_{j_i}^{p_i}(2^{j_i}t - k)\}_{k \in Z}$. Объединение соответствующих базисов вейвлет-пакетов $\{2^{j_i/2} \Psi_{j_i}^{p_i}(2^{j_i}t - k)\}_{k \in Z, 1 \leq i \leq l}$ определяет ортонормированный базис W_j , что позволяет полностью восстановить функцию.

Выделение и анализ характерных составляющих временного ряда на основе совместного применения вейвлет-пакетов и нейронных сетей

Нейронная сеть строит отображение $y: f \rightarrow f'$. Множество весовых коэффициентов входных связей нейрона представляет собой вектор-столбец [13]

$$U = [u_1, \dots, u_N]^T,$$

где N – длина входного вектора сети.

Если \hat{f}' действительный выход сети, а f' – желаемый, то $f' = y(f)$ – неизвестная функция, а $\hat{f}' = G(f, U)$ – ее аппроксимация, которую воспроизводит нейронная сеть. Процедура обучения сети сводится к минимизации среднеквадратической ошибки аппроксимации по параметру U .

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 $[l+1, l+\alpha]$, где l – текущий дискретный момент времени; α – длина интервала упреждения.

Ошибка решения 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 $\varepsilon_i(l) = \hat{f}'_i(l) - f'_i(l)$,

где l – текущий момент времени, i – текущая позиция на интервале упреждения.

Алгоритм формирования обучающего и контрольного множеств:

1. Исходный массив данных $\{f(k)\}_{k=1}^K$, где K – длина выборки, делим на L блоков длины $Q: \{f(k)\}_{k=1}^K = (\{f(k)\}_{k=1}^Q, \{f(k)\}_{k=2}^{Q+1}, \dots, \{f(k)\}_{k=K-Q}^K)$.

2. На основе конструкции *вейвлет-пакетов* для каждого блока s имеем представление f в виде линейной комбинации разномасштабных составляющих:

$$f^s = f_1^s + f_2^s + \dots + f_p^s,$$

где каждая компонента $f_i^s = \sum_{(j_i, k) \in I_s^{p_i}} \beta_{j_i, k}^s \Psi_{j_i}^{p_i}$, $\Psi_{j_i}^{p_i} \in W_{j_i}^{p_i}$ в вейвлет-пространстве

единственным образом определяется последовательностью коэффициентов $\bar{\beta}_{j_i}^s = \{\beta_{j_i, k}^s\}_{(j_i, k) \in I_s^{p_i}}$,

$\beta_{j_i, k}^s = \langle f^s, \Psi_{j_i}^{p_i} \rangle$, $W_{j_i}^{p_i}$ – пространства *вейвлет-пакета*.

3. Каждая выделенная компонента определяет подпространство пространства признаков временного ряда. Так как $W_{j_i}^{p_i}$ – пространства *вейвлет-пакетов*, получаем

$$\bigcap_{i=1}^l W_i^{p_i} = \{0\}, \quad \bigcup_{i=1}^l W_i^{p_i} = V.$$

Таким образом, для каждого блока s получаем разнесение в пространстве признаков данных (рис.1). Используя следующие наборы выделенных признаков

$$\begin{aligned} & \{f_{j_1, p_1}^s\}_{s=1, \dots, L}; \{f_{j_1, p_2}^s\}_{s=1, \dots, L}; \dots; \{f_{j_1, p_l}^s\}_{s=1, \dots, L}; \dots; \\ & \{f_{j_1, p_1}^s\}_{s=1, \dots, L}; \{f_{j_1, p_1}^s, f_{j_1, p_2}^s\}_{s=1, \dots, L}; \dots; \{f_{j_1, p_1}^s, f_{j_1, p_2}^s\}_{s=1, \dots, L}; \\ & \dots; \{f_{j_1, p_1}^s, f_{j_1, p_2}^s, f_{j_1, p_3}^s\}_{s=1, \dots, L}; \dots \\ & \{f_{j_1, p_1}^s, f_{j_1, p_2}^s, \dots, f_{j_1, p_l}^s\}_{s=1, \dots, L}; \dots; \\ & \{f_{j_1, p_1}^s, f_{j_1, p_2}^s, \dots, f_{j_1, p_l}^s\}_{s=1, \dots, L} \end{aligned}$$

формируем обучающие и контрольные множества для нейронных сетей.

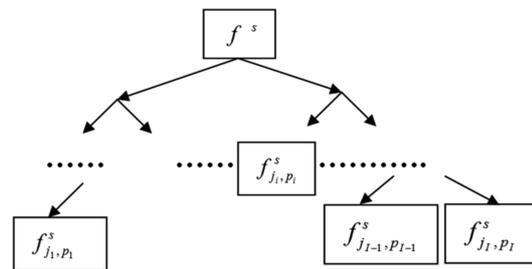


Рис.1. Схема разнесения данных в пространстве вейвлет-образов

Алгоритм построения «наилучшей» сети:

Шаг 1: Выполняем вейвлет-восстановление составляющей f_{j_1, p_1}^s для каждого блока данных s и на основе комбинаций восстановленных данных из различных блоков формируем обучающее множество. Строим *сеть 1 переменной структуры* [13] (сеть *переменной струк-*

туры – это многослойная сеть прямой передачи сигнала, архитектура которой определяется путем минимизации ошибки решения на множестве обучающих векторов), выполняем ее обучение и тестирование.

Шаг 2: Выполняем вейвлет-восстановление составляющих f_{j_1, p_1}^s для каждого блока данных s и на основе комбинаций восстановленных данных из различных блоков формируем обучающее множество. Строим сеть 2 переменной структуры, выполняем ее обучение и тестирование.

И т.д.

Шаг г: Выполняем вейвлет-восстановление составляющих $f_{j_1, p_1}^s, f_{j_1, p_2}^s, \dots, f_{j_1, p_l}^s$ для каждого блока данных s и на основе комбинаций восстановленных данных из различных блоков формируем обучающее множество. Строим сеть r переменной структуры, выполняем ее обучение и тестирование.

На основе анализа результатов работы полученных нейронных сетей определяем «наилучшую»: в качестве «наилучшей» сети определяем сеть, имеющую наименьшую ошибку решения на тестовом множестве

$$E_{M, \min} = \min_{\alpha} \left(\frac{1}{M} \sum_{l=1}^M \sum_{i=1}^f \varepsilon_i(l)^2 \right), \quad (7)$$

где α - номер нейронной сети, $\alpha = \overline{1, r}$, M - длина анализируемого выходного вектора сети f - длина интервала упреждения.

Обучающий набор данных - это набор наблюдений, содержащих признаки изучаемого процесса. На основе конструкции вейвлет-пакетов мы имеем разнесение в пространстве признаков данных. При обучении и проектировании каждая сеть изучает подмножество признаков входных данных и аппроксимирует их. «Наилучшая» сеть – это сеть, имеющая наименьшую ошибку решения на тестовом множестве. Поэтому используемое при обучении «наилучшей» сети подмножество данных будет содержать наиболее характерные признаки изучаемого процесса. В вейвлет-пространстве это подмножество представляется набором коэффициентов $\{a_{j,n}\}_{(j,n) \in I_A}$, определяющих компоненту $f_1(t)$ модели (3) временного ряда.

Если в данных возникает аномальная особенность, то происходит изменение их структуры. Поэтому операция выделения аномальных особенностей на основе нейронной сети может быть построена путем обработки и анализа ошибок решения ε_i :

если

$$E_Z = \frac{1}{Z} \sum_{l=1}^Z \sum_{i=1}^f \varepsilon_i(l)^2 \geq P, \quad (8)$$

где Z – длина окна наблюдения, P – наперед заданное пороговое значение, в пределах анализируемого временного окна имеем аномалию.

Результаты экспериментов

В экспериментах использовались данные f_0F2 , полученные автоматической ионосферной станцией, расположенной в с. Паратунка (п-ов Камчатка). Регистрация данных происходит один раз в час. Для экспериментов

были взяты результаты измерений f_0F2 за период с 1979 г. по 2011 г. При выполнении анализа, для определения степени магнитосферной возмущенности, характеризующей активность Солнца, использовались данные магнитного поля Земли (Н-компонента). В качестве базисных функций использовался класс ортогональных вейвлетов Добеши: db2, db3, db4.

Следуя результатам работ [2, 9], при выделении аномалий на основе операции (4) использовались пороговые значения, определяемые в процессе работы алгоритма по формуле:

$$T_j = \text{med}_{n,n=1, V} \left(|d_{j,n}| \right) + \theta * St_j,$$

где $St_j = \sqrt{\frac{1}{V-1} \sum_{n=1}^V \left(|d_{j,n}| - \bar{d}_{j,n} \right)^2}$, $\bar{d}_{j,n}$ - среднее значение, определяемое в пределах анализируемого скользящего временного окна длины V , $V=168$ отсчетов,

med - медиана, определяемая в пределах анализируемого скользящего временного окна длины V . Коэффициент $\theta = 3$ был определен статистически. Выделенные частотно-временные интервалы, содержащие аномальные особенности, показаны на рис. 2-5.б) оттенками серого цвета. Изменения интенсивности ионосферных возмущений во времени анализировались на основе величины (5) (рис. 2-5.в)).

На основе описанных выше алгоритмов были сформированы обучающие и контрольные множества для нейронных сетей и построена «наилучшая» сеть, имеющая три слоя и позволяющая выполнить прогноз данных f_0F2 с шагом упреждения 3 часа. Выделенная на основе «наилучшей» сети характерная компонента временного ряда f_0F2 имеет вид:

$$f_1(t) = \sum_{j_i, k} a_{j_i, k} \Psi_{j_i}^{p_i}, \Psi_{j_i}^{p_i} \in W_{j_i}^{p_i}, j_i = 3, p_i = 1, k \in Z.$$

Анализ ошибок решения нейронных сетей показал, что базисная функция Добеши порядка 3 обеспечивает наименьшую погрешность аппроксимации данных f_0F2 за анализируемые временные периоды.

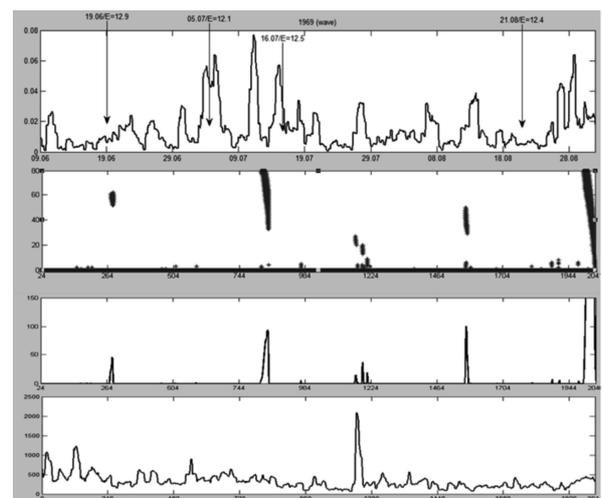


Рис.2. Результаты обработки данных f_0F2 за 1969 г.:

- а) – вектор ошибки нейронной сети;
- б) – частотно-временные интервалы, содержащие аномальные особенности;
- в) – интенсивность аномалий;
- г) – Н-компонента магнитного поля Земли. Стрелками отмечены моменты возникновения землетрясений

Анализ рис. 2-5.а) показывает, что в периоды повышения сейсмической активности наблюдается увеличение ошибки нейронной сети, характеризующее наличие в данных аномальных особенностей. Выделенные на основе дискретного вейвлет-преобразования аномалии (операция (4), рис. 2-5.б)) также подтверждают этот результат. Детальный анализ аномалий показывает, что они неравномерно распределены и по времени и по масштабам и характеризуются различной интенсивностью (величина $E_{f(t)}$, рис. 2-5.в)).

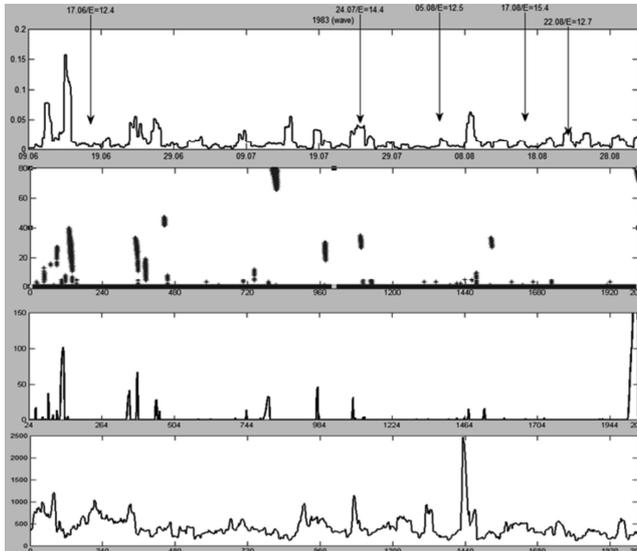


Рис.3. Результаты обработки данных fOF2 за 1983 г.:
 а) – вектор ошибки нейронной сети;
 б) – частотно-временные интервалы, содержащие аномальные особенности;
 в) – интенсивность аномалий;
 г) – N-компонента магнитного поля Земли. Стрелками отмечены моменты возникновения землетрясений

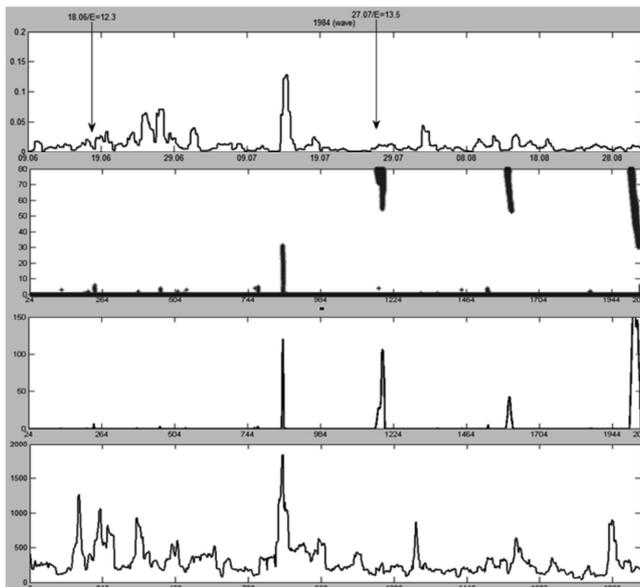


Рис.4. Результаты обработки данных fOF2 за 1984 г.:
 а) – вектор ошибки нейронной сети;
 б) – частотно-временные интервалы, содержащие аномальные особенности;
 в) – интенсивность аномалий;
 г) – N-компонента магнитного поля Земли. Стрелками отмечены моменты возникновения землетрясений

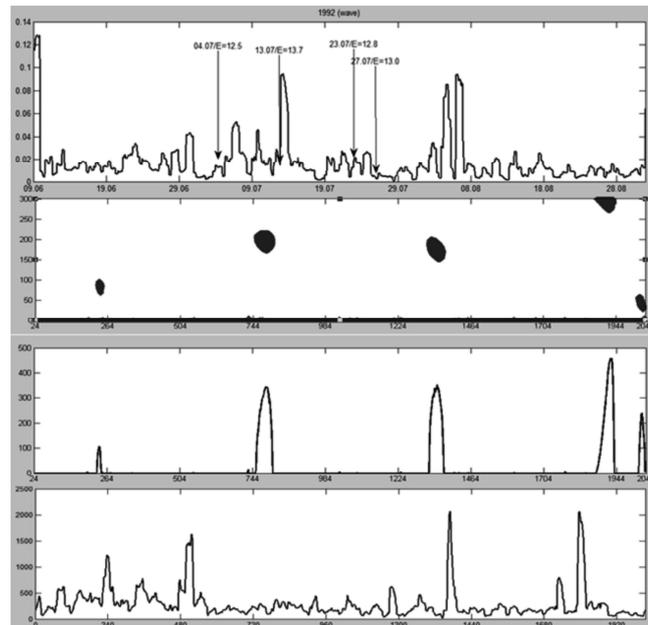


Рис.5. Результаты обработки данных fOF2 за 1992 г.:
 а) – вектор ошибки нейронной сети;
 б) – частотно-временные интервалы, содержащие аномальные особенности;
 в) – интенсивность аномалий;
 г) – N-компонента магнитного поля Земли. Стрелками отмечены моменты возникновения землетрясений

Сопоставление полученных результатов с данными магнитного поля Земли (рис.2-5.г)) показывает, что анализируемые литосферные процессы в большинстве случаев наблюдаются на фоне повышенной солнечной активности.

Заключение

На примере данных fOF2 для изучения временных особенностей параметров ионосферы и выявления аномалий, возникающих в периоды повышенной солнечной или сейсмической активности, предложен метод, основанный на совмещении вейвлет-преобразования и нейронных сетей. Разработаны автоматические алгоритмы выделения и анализа характерных составляющих ряда fOF2.

Апробация метода на данных, полученных автоматической ионосферной станцией Паратунка (п-ов Камчатка), подтвердила его эффективность и позволила выявить аномальные особенности, возникающие в периоды возрастания солнечной активности и накануне сильных землетрясений на Камчатке. Выделенные характерные составляющие ряда fOF2 позволили проанализировать вариации ионосферных параметров в летний период времени и их существенное изменение в периоды возрастания сейсмической и солнечной активности. Детальный анализ выделенных аномальных особенностей показал, что в периоды возрастания сейсмической или солнечной активности в вариациях ряда fOF2 возникают локальные разномасштабные периодичности, имеющие неравномерное распределение и по времени и по масштабам.

Работа поддержана грантом Президента Российской Федерации МД-2199.2011.9, грантом РФФИ – ДВО РАН

№11-07-98514-р_восток_а и грантом «У.М.Н.И.К.» - №8283р/10269 от 30.06.2010 г.

Данные сейсмического каталога любезно представлены Камчатским филиалом геофизической службы РАН (г. Петропавловск-Камчатский).

Литература

1. Дёмин М.Г. Ионосфера Земли. Плазменная гелиогеофизика. – М.: Физматлит, 2008. -Т.ИИ, -С.92-163.

2. Мандрикова О.В., Полозов Ю.А., Пережогин А.С., Вейвлет-технология анализа ионосферных данных // Научные ведомости Белгородского государственного университета, Серия «История. Политология. Экономика. Информатика»: Белгород. 2011. -№ 19. -С. 113-118.

3. Мандрикова О. В., Полозов Ю.А. Критерии выбора вейвлет-функции в задачах аппроксимации природных временных рядов сложной структуры // Информационные технологии. - Москва. 2012 г. -№1. -С. 31 – 36.

4. Мандрикова О.В. Многокомпонентная модель сигнала со сложной структурой // Проблемы эволюции открытых систем. 2008. -Вып. 10. -Т. 2. - С.161-172.

5. Полозов Ю.А. Метод формирования обучающего множества для нейронной сети на основе вейвлет-фильтрации // Известия вузов, Северо-Кавказский регион, – Ростов-на-Дону, Серия естественные науки. 2010. - №3. - С. 12-16.

6. Краткосрочный прогноз катастрофических землетрясений с помощью радиофизических наземно-космических методов: докл. конф. - М.: ОИФЗ РАН, 1998. -164 с.

7. Липеровская Е.В., Липеровский В.А., Похотелов О.А. О возмущениях в F-области ионосферы перед землетрясениями // Геофизические исследования. - 2006. - № 6. -С. 51-58.

8. Намгаладзе А. А. Физический механизм и математическое моделирование ионосферных предвестников землетрясений, регистрируемых в полном электронном содержании // Геомагнетизм и аэронавигация. -2009. - Т. 49. -№2. -С. 267-277.

9. Мандрикова О.В. Горева Т.С. Метод идентификации структурных компонентов сложного природного сигнала на основе вейвлет-пакетов. – Москва: Цифровая обработка сигналов.-2010 г.-№1.- с.45-50.

10. 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.

11. S. Mallat A Wavelet tour of signal processing [пер. с англ.] -М.: Мир, 2005. -671 с.

12. Добеши И. Десять лекций по вейвлетам [пер. с англ.] - Ижевск:НИЦ «Регулярная и хаотическая динамика», -2001. -464 с.

13. Нейроматематика: учеб. пособие для вузов / Агеев А.Д., [и др.]; общая ред А.И. Галушкина. – М.:ИПРЖР, 2002. -448 с.

14. Бархатов Н.А., Ревунов С.Е. Прогнозирование критической частоты ионосферного слоя F2 методом искусственных нейронных сетей. VIII Нижегородская сессия молодых ученых. Естественнонаучные дисциплины, 20-25 апреля 2003 г., Дзержинск, Тезисы докладов, Н. Новгород, 2003. -С.98-99.

15. Бархатов Н.А., Ревунов С.Е., Урядов В.П. Технология искусственных нейронных сетей для прогнозирования критической частоты ионосферного слоя F2. // Известия ВУЗов «Радиофизика», 2005. -Т.48.- С.1-15.

METHOD OF ALLOCATION OF ABNORMAL FEATURES IN DATA OF CRITICAL FREQUENCY OF THE IONOSPHERE ON THE BASIS OF COMBINATION WAVELET-TRANSFORMATION AND NEURAL NETWORKS

Mandrikova O.V., Polozov Yu.A.

In work the method of automatic allocation of the abnormal features arising in a registered time number of critical frequency of an ionosphere f_0F_2 during the periods of raised seismic or solar activity is offered. The method is based on joint application of wavelet-transformation and neural networks. On the basis of wavelet-transformation algorithms on detection of features and estimation of their parameters are developed. Allocation and the analysis of characteristic components of a time number is carried out on the basis of joint application of wavelet-transformation with neural networks. Method approbation is executed on the data f_0F_2 , received on an observatory «Paratunka» (Paratunka, the Kamchatka edge).

Уважаемые коллеги!

Для тех, кто не успел оформить подписку на второе полугодие 2012 года через ОАО «Роспечать», сохраняется возможность приобретения журналов непосредственно в редакции по адресу:

107031, г. Москва, Рождественка, 6\9\20, стр. 1,

Российское научно-техническое общество радиотехники, электроники и связи им.

А.С. Попова, или оформить заказ в соответствии с требованиями,

выставленными на сайте журнала: www.dsra.ru.

Справки по телефонам: (495) 621-71-08, 621-06-10.

Факс: (495) 621-16-39. E-mail: rntores@mail.ru