



УДК 523.98

ПРОГНОЗИРОВАНИЕ ФУНКЦИИ ЧИСЛА СОЛНЕЧНЫХ ПЯТЕН В ЦИКЛЕ СОЛНЕЧНОЙ АКТИВНОСТИ НА ОСНОВЕ МЕТОДА ИСКУССТВЕННОЙ НЕЙРОННОЙ СЕТИ

И. В. Крашенинников^{1,2}, С. О. Чумаков¹¹Институт Земного магнетизма, ионосферы и распространения радиоволн им. Н.В. Пушкова, г. Москва, г. Троицк, Россия²Институт прикладной геофизики им. акад. Е.К. Федорова, г. Москва, Россия

Анализируется возможность прогнозирования функции числа солнечных пятен (SSN) в цикле солнечной активности на основе применения платформы искусственной нейронной сети Элмана к историческому ряду данных обсерваторских наблюдений. Предложен метод нормализации исходных данных – построения виртуальных идеализированных циклов, используя масштабируемые коэффициенты по времени и значениям максимумов в циклах солнечной активности. Корректность метода рассмотрена в численном моделировании временного ряда SSN. Оценены интервалы изменения адаптируемых параметров нейронной сети и предложен математический критерий для выбора решения. Характерным свойством построенной функции числа солнечных пятен является значительная асимметрия восходящей и спадающей ветвей внутри цикла. Представлен прогноз временного хода на текущий 25-й цикл солнечной активности и обсуждается его общая корректность в сравнении с существующими результатами прогнозирования солнечной активности.

КЛЮЧЕВЫЕ СЛОВА: число солнечных пятен, SSN, долгосрочное прогнозирование, солнечный цикл, искусственная нейронная сеть

DOI 10.5425/2304-7380_2022_35_34

<https://elibrary.ru/hkcwvb>

1. ВВЕДЕНИЕ

Долгосрочный прогноз солнечной активности является одним из важнейших факторов космической погоды. Как ключевой управляющий индекс, прогнозные данные солнечной активности (СА) в виде числа солнечных пятен (solar sunspot number – SSN) и потока солнечного радиоизлучения (solar radioflux – $F_{10.7}$), входят в прогностические ионосферные модели, на основе которых, в частности, осуществляется долгосрочное планирование работы ионосферных радиокommunikационных систем. Традиционно требуемый долгосрочный прогноз солнечной активности для условий прохождения радиоволн охватывает временной интервал от одного месяца до 2-3 лет вперед и наиболее известной его реализацией является метод Вальдмайера [1], используемый как официальный в SIDC (Solar Influences Data Analysis Center, Brussel). На рисунке 1 в верхней части



левой панели приведен пример применения данного подхода в ноябре 2019 г. к сглаженным среднемесячным данным (представлены кривыми) и видно существенное расхождение с экспериментальными данными (полые треугольники), в частности, прогнозируемый минимум SA (начало 25-го цикла) смещен примерно на один год вперед от его фактического значения (начало 2020 г.). И соответственно смещается максимум, который по прогнозу приходится на 2022 г. Однако, еще более неприятная ситуация с другим индикатором SA – потоком радиоизлучения $F_{10.7}$. Как видно из рис.1 (нижняя часть левой панели), прогнозные значения $F_{10.7}$ в системе контроля космической погоды SWPC (Space Weather Prediction Center, Boulder), по-видимому, единственном источнике долгосрочной прогнозной информации по солнечному радиоизлучению, уходят ниже минимально возможной величины для данного параметра. И, более того, отсутствует какая-либо видимая корреляция в поведении этих двух индикаторов одного процесса – вариаций SA (рис. 1, верхняя и нижние части левой панели). Т.е. традиционные методы прогнозирования могут в сложных ситуациях давать совершенно некорректные результаты.

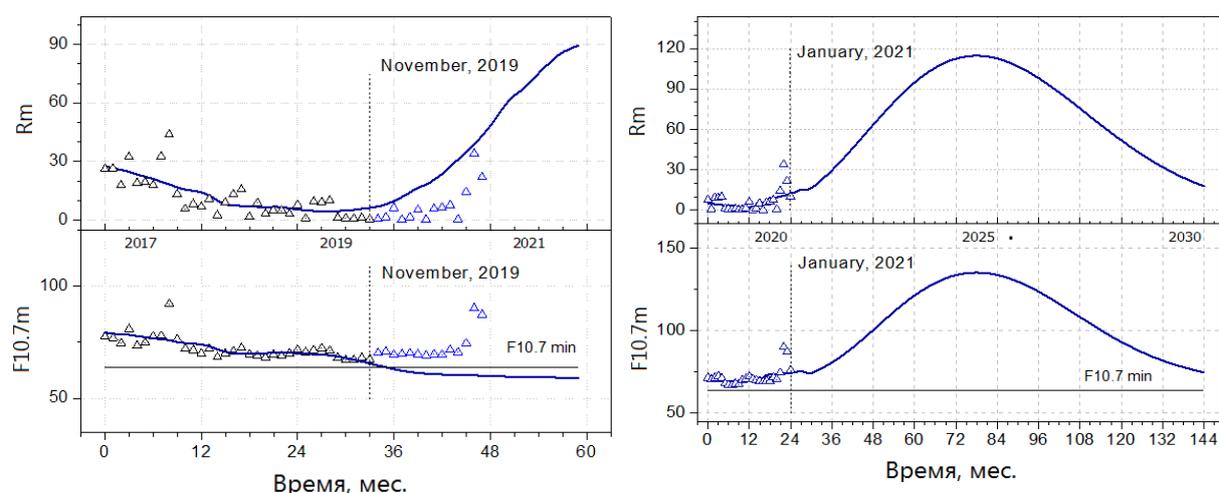


Рис. 1. Прогноз параметров солнечной активности (среднемесячные данные): традиционный подход (3 года) на ноябрь 2019 г. (левая панель) и с переходом на полный цикл на январь 2021 г. (правая панель). Полыми треугольниками отмечены экспериментальные данные

Квазипериодический характер временной зависимости числа солнечных пятен дает возможность применить различные математические методы выделения базовой закономерности, как основы прогнозирования, в данных наблюдений. В частности, это метод искусственных нейронных сетей (ИНС) в анализе временных рядов данных. Первые попытки применения ИНС к долгосрочному прогнозированию солнечной активности были рассмотрены в работах [2], в дальнейшем данный подход получил развитие в ряде работ (обзор [4]), и активно развивается в настоящее время, например, [5-7], как применение элементов искусственного интеллекта в поиске скрытой закономерности в серийных экспериментальных данных. Другим направлением решения данной задачи является нелинейный динамический анализ в хаосе, например, работы [8,9]. Также следует отметить исследования по возможности прогнозирования максимума SSN в цикле на основе прекурсоров в предыдущем цикле (циклах), в частности, основываясь на интенсивности геомагнитных возмущений (дневной A_p – индекс) [10,11].

С 2021 г. SWPC переходит на другую основу в долгосрочном прогнозировании солнечной активности (рис. 1, правая панель), по-видимому, опираясь на результаты применения нейросетевого подхода к целому циклу SA, как базовому объекту во временной периодической последовательности данных наблюдений.

В настоящей работе, на основе платформы рекуррентной ИНС, рассматривается возможность долгосрочного прогнозирования на масштабе цикла параметра солнечной активности – временной функции SSN, применяя технологию нормализации исходного временного ряда данных. Оценивается эффективность предлагаемого метода прогнозирования на примере предыдущих четырех циклов солнечной активности, с 21-го по 24-й, и строится прогноз на текущий 25-й цикл.

2. ИНС ЭЛМАНА

В настоящее время существует более 20 платформ реализаций искусственных нейронных сетей для различных объектов приложения. В применении к временным рядам часто используются рекуррентные нейронные сети (recurrent networks), характеризующиеся как прямым (feed forward), так и обратным (feed back) распространением информации и наличием обратных связей, по которым передаются результаты обработки сетью данных на предыдущем этапе. В результате этого входом рекуррентной нейронной сети в каждый фиксированный момент времени является вектор входных данных и результаты обработки информации сетью на предыдущем этапе. Обучение таких сетей базируется на алгоритме обратного распространения ошибки [13, 14]. Так же, для задач предсказания (экстраполяции) временных рядов применяются алгоритмы глубокого (глубинного) обучения (deep learning) для глубоких многослойных перцептронов прямого распространения, например, [3,6]. В данной работе, как и в [5], использовалась рекуррентная нейронная сеть Элмана [12], разработанная для выявления внутренних закономерностей (структур) во временных рядах данных.

Квазипериодическая структура солнечных данных является подходящей кандидатурой для такой платформы. Общая схема такой ИНС приведена на рис. 1. Рекуррентными нейронными сетями называются конфигурации, в которых выходы нейронных элементов последующих слоёв имеют синаптические соединения (связи) с нейронами предшествующих слоёв. Это приводит к возможности создания моделей ИНС, обладающих памятью, т.е. возможностью запоминать процесс. Таким образом, строится ИНС, ответ которой зависит не только от входного сигнала, подаваемого в данный момент на вход ИНС, но и от тех сигналов, которые обрабатывались нейросетью в предшествующие моменты времени. Такая ИНС обладает нелинейной внутренней памятью, заключённой в петле обратной связи, что позволяет накапливать и использовать информацию о предыстории процесса. Рекуррентные сети могут использоваться для решения задач прогнозирования, как в нашем случае, и управления [13, 14]. Временные ряды индексов солнечной активности представляют собой квазипериодические процессы, и, следовательно, для их прогнозирования необходима внутренняя память.

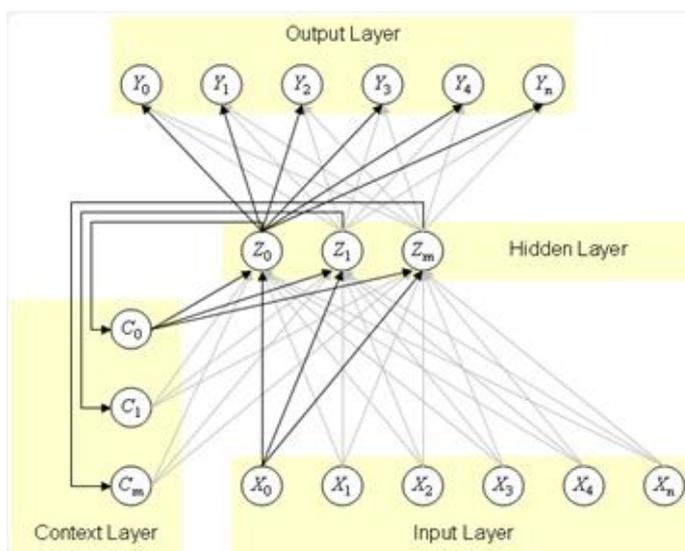


Рис. 2. ИНС Элмана – рекуррентная сеть с обратными связями от нейронов скрытого слоя

В ИНС Элмана выходы нейронных элементов промежуточного (скрытого или внутреннего) слоя соединяются с нейронами контекстного слоя, выходы которых снова подаются на входы нейронов внутреннего слоя. И, таким образом, нейроны скрытого слоя имеют помимо синаптических связей с нейронами входного слоя также и обратные связи с контекстными нейронами. Число нейронов скрытого слоя, как правило, совпадает с числом нейронов контекстного слоя. Тогда взвешенная сумма i -го нейронного элемента промежуточного слоя [13, 14]:

$$S_i(t) = \sum_{j=1}^n w_{ji} x_j(t) + \sum_{k=1}^m w_{ki} c_k(t-1) - T_i \quad (1)$$

где n – число нейронов входного слоя или размерность вектора входных данных $x_j(t)$, w_{ji} – весовой коэффициент между j -м нейроном входного и i -м нейроном промежуточного слоёв (его величина определяет силу синоптической связи между соответствующими нейронами); m – число нейронов промежуточного слоя, w_{ki} – весовой коэффициент между k -м контекстным нейроном и i -м нейроном промежуточного слоя, $c_k(t-1)$ – выходное значение k -го нейрона внутреннего (промежуточного или скрытого) слоя на предыдущем шаге вычисления его значения, которое сохраняется в k -ом контекстном нейроне; T_i – пороговое значение i -го нейронного элемента промежуточного слоя. Выходное значение i -го нейрона промежуточного слоя определяется следующим образом:

$$c_i(t) = F(S_i(t)),$$

где в качестве функции нелинейного преобразования F (или функции активации нейронов скрытого слоя) обычно используется гиперболический тангенс или сигмоидная функция. Применение обеих функций анализировалось в процессе численного моделирования и, в конечном счёте, была выбрана функция гиперболического тангенса. В выходном слое сеть имеет один нейрон с линейной функцией активации, т.е. значением выходного нейрона является линейная комбинация значений нейронов скрытого слоя:

$$y(t) = \sum_{k=1}^m v_k c_k(t) - T, \quad (2)$$

где v_k – весовой коэффициент между k -м нейроном скрытого слоя и выходным нейроном, $c_k(t)$ – выходное значение k -го нейрона скрытого слоя, T – пороговое значение нейрона выходного слоя. Для обучения рекуррентной нейронной сети применяется алгоритм обратного распространения ошибки [13, 14].

Общими моментами работы ИНС, помимо выбора рабочей платформы в применении к конкретной задаче, являются следующие необходимые этапы:

- подбор топологии нейронной сети (выбор оптимального соотношения чисел нейронов в каждом слое);
- нормализация исходных данных под выбранную нейросеть;
- обучение ИНС при помощи алгоритма обратного распространения ошибки;
- экспериментальный подбор управляющих параметров ИНС (интервалы варьирования скорости обучения и инерции обучения при обучении ИНС и построении корректного решения);
- тестирование на модельных задачах и реальных данных с известным результатом.

Следует отметить, что итерационным процессом обучения ИНС является процесс нахождения глобального или приемлемого локального минимума целевой функции в многомерном пространстве весовых коэффициентов: w_{ji} , w_{ki} , v_k , T_i , T (формулы (1), (2)) для всего набора тренировочных данных. Целевой функцией в данном случае является сумма квадратов отклонений значений $SSN(t)$ от $y(t)$ на всём наборе тренировочных данных.

Топология нейросети была выбрана, как и в [5] в следующей конфигурации: число нейронов входного слоя равнялось 6, число нейронов скрытого слоя и число контекстных нейронов равнялось 10, выходной слой состоял из единственного нейрона с линейной функцией активации. Это означает, что для прогнозирования индекса Rm – значения сглаженного числа солнечных пятен на данный момент необходимо подать на вход обученной ИНС значения этого индекса за 6 предыдущих временных интервалов. Методика нормализации исходных данных и тестирование рассмотрены в ходе численного моделирования и далее применены реальным данным. Здесь отметим только, что в данной работе под нормализацией данных понимается не стандартная нормировка данных в теории ИНС, когда весь временной ряд, предназначенный для обучения ИНС, нормируется на единственный нормировочный коэффициент, а локальная нормировка при которой данные чисел солнечных пятен в каждом отдельном цикле солнечной активности (СА) нормировались на соответствующий максимум этого солнечного цикла, и в результате в каждом отдельном солнечном цикле максимум нормализованных значений равнялся единице.

3. ЧИСЛЕННОЕ МОДЕЛИРОВАНИЕ

Особенностью нейросетевого подхода к прогнозированию временных рядов является проблема устойчивости построения решения – нахождения глобального или приемлемого минимума целевой функции в итерационном процессе обучения ИНС. Как правило, не удается выбрать постоянные управляющие параметры ИНС в итерационном процессе обучения в различных условиях реальных данных или построить адаптивную процедуру их подбора. Для сети Элмана такими параметрами являются скорость и инерция (момент) обучения в итерационном процессе поиска решения [13,14], которые можно оценить в процессе численного моделирования. Для модельных задач в численных экспериментах с нашей моделью ИНС в качестве базовой функции формирования цикла солнечной активности использовалось следующее представление для среднемесячного сглаженного индекса SSN

$$R_m(t) = \left\{ \begin{array}{l} A_0/2 \left(1 + \sin \left(\frac{\pi t}{T_1} - \frac{\pi}{2} \right) \right), \quad T_1 \geq t \geq 0 \\ A_0/2 \left(1 + \sin \left(-\frac{\pi(t-T_1)}{T_2} + \frac{\pi}{2} \right) \right), \quad T_2 \geq t \geq T_1 \end{array} \right\}, \quad (3)$$

где T_1 и T_2 – длительности восходящей и спадающей ветвей в цикле ($T_1 \leq T_2$), $T_0 = T_1 + T_2$ – длительность всего цикла, A_0 – амплитуда в цикле. Параметры A_0 и T_0 модулировались псевдослучайной последовательностью с $\delta A_0/A_0 \sim 0.5$, $\delta T/T_0 \sim 0.1$ и сохранением соотношения (здесь изменение в математике!!!!) $T_1/T_2 \sim 0.5$ для каждого цикла. Пример временного ряда синтезированной последовательности циклов, моделирующей исторический ряд данных СА, представлен на рис. 3 (верхняя часть верхней панели), на которой видны вариации как амплитуды, так и длительности циклов, и асимметрия функциональной зависимости индекса. Несмотря на достаточно высокую степень идеализации циклической последовательности индекса SSN, прямое применение ИНС к прогнозированию конкретного цикла на исходных синтезированных данных имеет довольно низкую устойчивость результата, который зачастую просто некорректен с точки зрения цикличности процесса с близким к нулю минимумом. На этапе нормализации исходных данных под ИНС был разработан метод введения абстрактного идеализированного представления цикла, имеющего единичную амплитуду и стандартную длительность в 132 условных месяца. Т.е., для каждого цикла вводились коэффициенты трансформации: $1/A_0^i$ и T_N/T_0^i , где i -индекс цикла, T_N - нормализованная длительность цикла, т.е. $T_N = 132 = 11 \text{ лет} \cdot 12 \text{ мес}$. Нижняя часть верхней панели на рис. 3 отображает такую нормализованную временную зависимость синтезированных данных. Кроме того, как и в работе [5], было применено прореживание данных с коэффициентом 5 (в [5] он равнялся 6) и, таким образом, были сформированы нормализованные данные для процесса обучения ИНС (нижняя часть верхней панели, рис. 3). В нижней части рис. 3 представлены результаты прогнозирования методом ИНС для 23-го синтезированного цикла СА. Базовый прогноз ИНС в форме идеализированного (абстрактного) цикла с прореженными данными отмечен пустыми кружочками на фоне исходной кривой (1) (левая нижняя панель). В реальном масштабе времени из прогноза ИНС с известными коэффициентами трансформации получаем прогноз с не нормированным (реальным) значением R_m – правая нижняя панель.

Следует отметить значительное повышение устойчивости результата оценки функциональной зависимости SSN внутри цикла при уменьшении степеней свободы задачи – разделении общего процесса прогнозирования солнечного цикла на парциальные части: амплитуду, длительность и временной ход внутри цикла. Была исследована возможность работы с данными в динамическом режиме, т.е. с фазовым сдвигом циклического интервала предсказания, и погрешность прогнозирования в нормализованном пространстве оставалась на уровне статического режима. Была показана принципиальная особенность ИНС Элмана – существование оптимальных значений для базовых параметров итерационного процесса обучения ИНС: скорости и инерции обучения – 0.05 и

0.5, что соответствует оценочным интервалам изменений этих параметров – [0.001–0.01] для скорости обучения и [0.1–1.0] для инерции (момента) обучения, приведенным в [12,13].

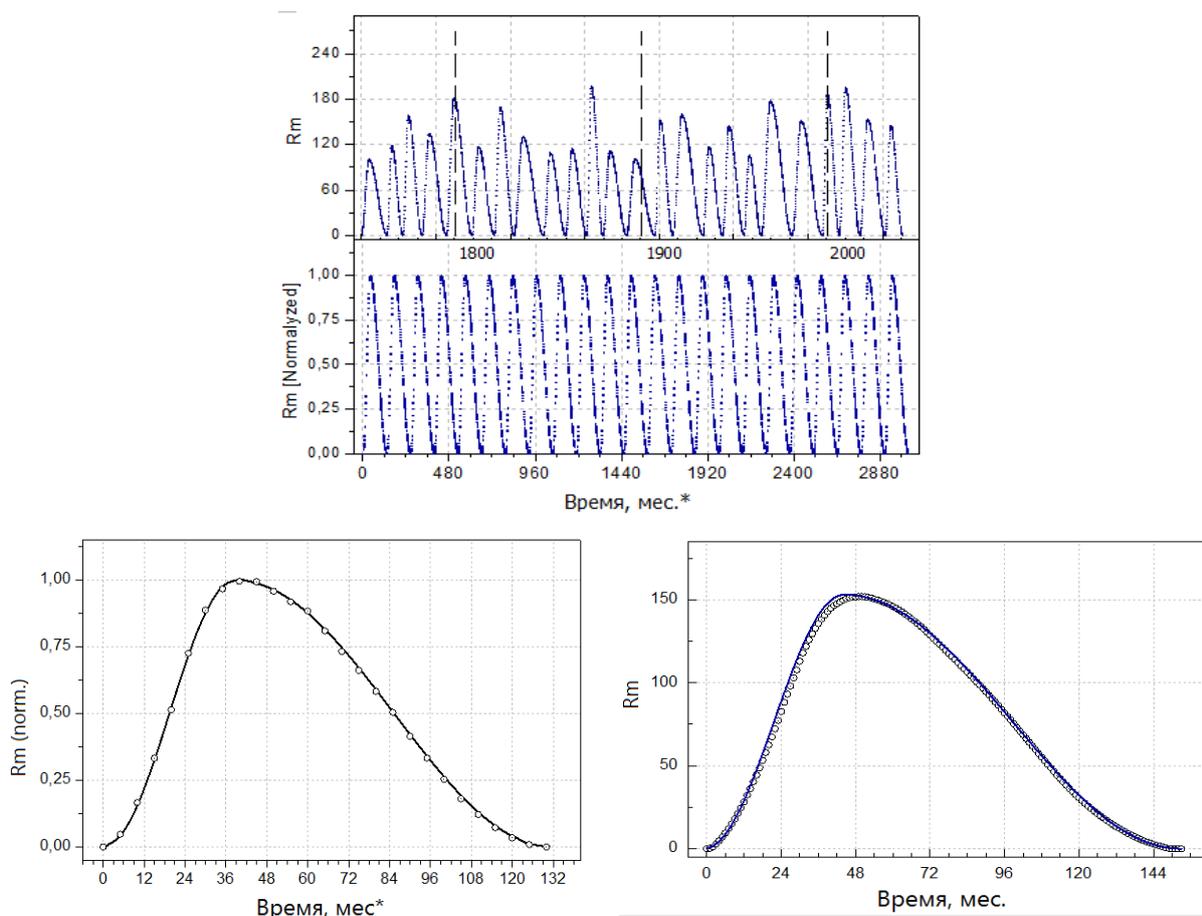


Рис. 3. Модельное представление временного хода среднемесячных сглаженных чисел солнечных пятен (верхняя панель) и прогнозирование 23-го цикла СА: нормализованные данные (левая нижняя панель) и исходные синтезированные данные (нижняя правая панель). Сплошными линиями представлены истинные кривые, а полыми кружочками отмечен результат прогноза ИНС

4. НОРМАЛИЗАЦИЯ ДАННЫХ И ПРОГНОЗИРОВАНИЕ

Реальные данные SSN имеют сложную структуру, как в периодичности, так и в вариациях максимумов в периодах, в частности, имеет место слабовыраженный переход циклов со значительными вариациями в минимуме солнечной активности. Корректная работа ИНС требует строгого математического разделения циклов – определения начала и конца цикла и более отчетливо выраженного переходного процесса. Для этого применялась процедура аппроксимации данных в окрестности минимума СА на интервале ± 12 мес. от текущего минимального значения SSN (близкого к астрономическому переходу) и определялась квадратичная (параболическая) зависимость $R_p(t)$ и далее само математическое положение минимума, которое приписывалось концу цикла. Следующая за минимумом точка считалась началом нового цикла и характеризовалась положительной временной производной. Далее выполнялась регуляризация хода $R_m(t)$ в окрестности минимума

$$R_m(t) = wR_p(t) + (1 - w)R_m(t), \quad w(t) = \exp\left\{-\frac{(t - t_{\min})^2}{\Delta t^2}\right\}$$

где $\Delta t = 6$ мес., что позволяло выделить переход циклов и избежать скачков $R_m(t)$ в области стыковки во временном ходе цикла (рис. 4, верхняя панель). На следующем этапе нормализации данных выполнялось преобразование в последовательность абстрагированных циклов с коэффициентами трансформации: $1/A_0^i$ и T_N/T_0^i , где i -индекс цикла, которая и служила основой для обучения ИНС.

Введение идеализированных циклов с общими краевыми параметрами – положительная производная в начале и нулевая в конце цикла позволяет осуществить выбор решения в вариационном процессе нахождения глобального максимума целевой функции ИНС. Корректным будет рассматриваться решение, которое удовлетворяет общим свойствам нормализованных данных на концах прогнозируемого цикла (рис. 4, левая нижняя панель): положительная производная в начале, близкая к нулю в конце цикла и максимальное значение близко к единице.

Как пример применения рассмотренного метода, результат предсказания 21-го цикла СА приведен на рис. 4, где также приведена усредненная по предыдущим циклам зависимость SSN (кривые 1). Усреднение по циклам является корректным, поскольку все нормализованные циклы имеют одинаковую размерность по координатам. Виден достаточно большой разброс функций, нормализованных данных в циклах, что проявляется в величинах доверительных интервалов (рис.4, правая нижняя панель), приведенных для нескольких точек на графике SSN. Сопоставление полученных методом ИНС и усреднённых зависимостей для числа солнечных пятен показывает общую характерную асимметрию восходящей и спадающей ветвей цикла и синхронность кривых достаточно высокая, что говорит о корректном нахождении главной части в периодическом процессе. В то же время, прогноз ИНС отличается от усреднённой кривой, что отражает индивидуальные свойства конкретного цикла.

Таблица 1 иллюстрирует итоговые результаты анализа солнечных данных в последних четырех циклах: с 21-го по 24-й. Хорошо видна большая варьированность параметров ИНС (скорости и инерции обучения ИНС) от цикла к циклу в полученном решении, что свидетельствует о значительной индивидуальности внутрициклической динамики SSN. Численная характеристика изменчивости приведена как показатель эффективности предсказания в цикле

$$PE = 1 - \frac{\sum_{i=1}^N |R_p^i - R_m^i|}{\sum_{i=1}^N R_m^i},$$

где R_p^i – прогнозное, R_m^i – экспериментальное значения SSN. Более низкие значения эффективности предсказания для 23-го и 24-го циклов, по-видимому, связаны с “двугорбым” характером распределения R_m внутри данных интервалов, что проявляется в прогнозе на 25-й цикл (рис. 5). Прогнозная кривая ИНС в нормализованном представлении (рис. 5, левая панель) имеет выраженный перегиб на спадающей ветви, т.е. предсказывается возможность формирования неразвитого “двугорбого” распределения по циклу. Также, как и для 21-го цикла, видна близость кривой ИНС к усредненной зависимости за предыдущие периоды временного ряда данных. Следует отметить значительное отличие в прогнозных кривых: SWPC (отмечена красным цветом на правой панели, рис. 5) и ИНС (выделена синим цветом) в реальном масштабе времени (рис. 5, правая панель). Значение максимума для прогноза ИНС взято в 120 единиц и период в 132 мес. (официальный прогноз NOAA от 10 Jan 2022, <https://spaceweatherarchive.com/2022/01/09/solar-cycle-25-update/>). В первую очередь это касается положения максимального значения цикла – для кривой прогноза ИНС это конец 2023 г., тогда как для базового прогноза SWPC – середина 2025 г. Экспериментальные данные (среднемесячные) отмечены полыми треугольниками и на июль 2022 г. имеет место существенная предпочтительность прогноза, построенного рассмотренным методом с нормализацией данных. Большое отклонение от официального первоначального прогноза отмечается и в бюллетенях NOAA.

Таблица 1. Характерные параметры применения метода ИНС к данным SSN

Номер цикла	Скорость обучения	Инерция обучения	RMS (норм.)	RMS (эсп.)	Эффективность предсказания
21	0.005	0.75	0.06	14.97	0.91
22	0.005	0.5	0.05	12.65	0.9
23	0.0095	0.2	0.05	21.37	0.79
24	0.001	0.1	0.07	12.85	0.79
Среднее			0.06	15.46	0.85

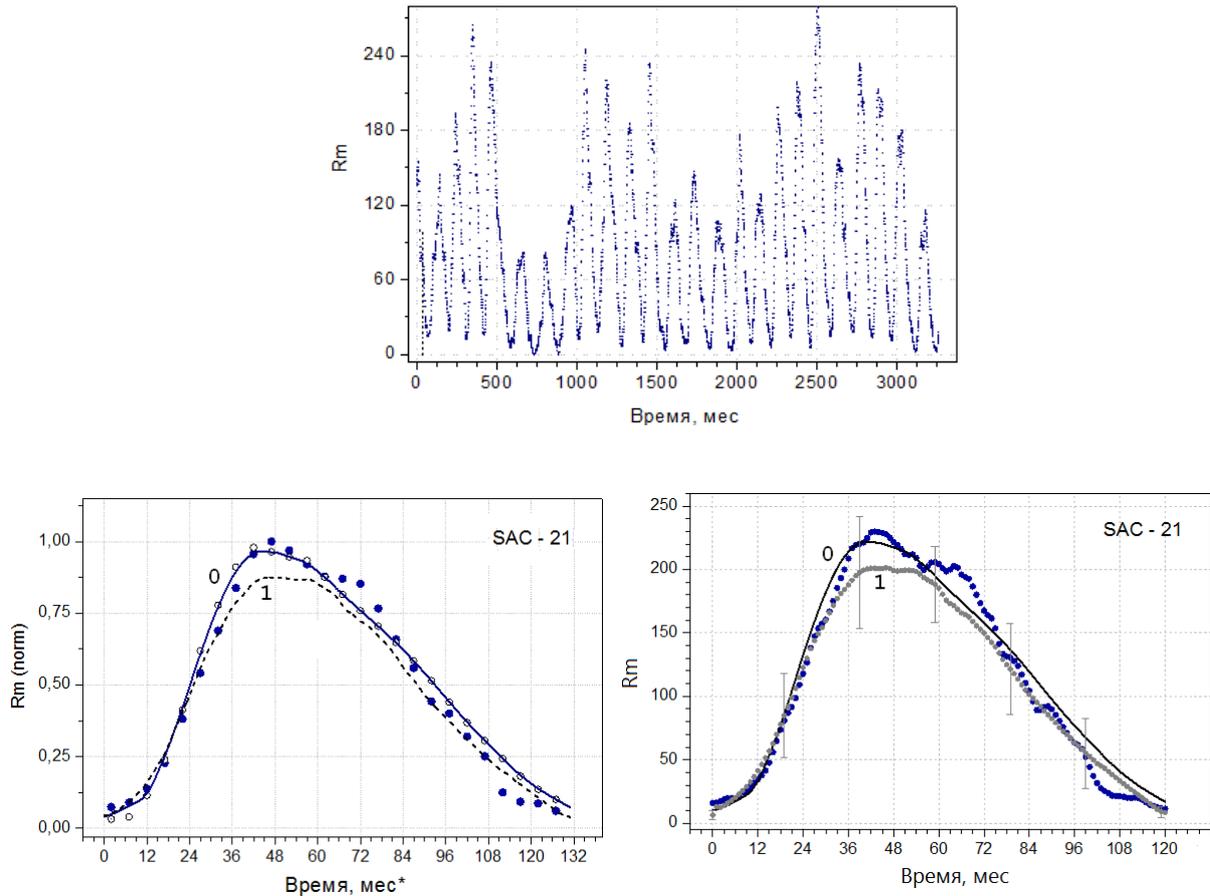


Рис. 4. Временной ход среднемесячных сглаженных чисел солнечных пятен (верхняя панель) и прогнозирование 21-го цикла: нормализованные данные (полые кружочки, левая нижняя панель) и реальные данные (нижняя правая панель). Заполненными точками (синий) представлены данные наблюдений, пунктирная линия – усредненные за предыдущие циклы результаты, а сплошными линиями – прогноз методом ИНС

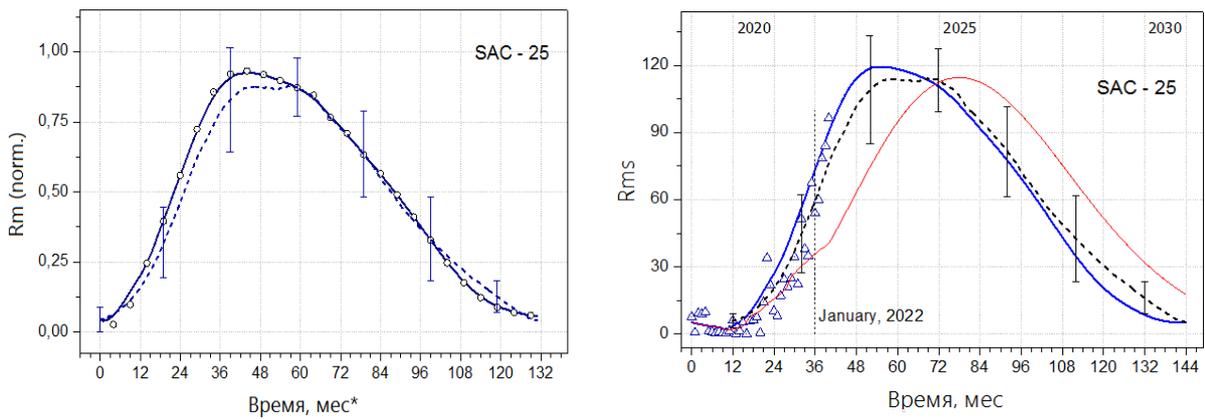


Рис. 5. Прогноз динамики числа солнечных пятен на 25-й цикл солнечной активности. Нормализованные данные (левая панель): полые кружочки – результат ИНС, пунктирная линия с доверительными интервалами – усредненные результаты за предыдущие циклы. В реальном масштабе данных (правая панель): полые треугольники – текущие данные наблюдений (среднемесячные), сплошная линия (синий цвет) – результат ИНС, сплошная линия (красный цвет) – долгосрочный прогноз SWPC (Boulder), пунктирная линия – результат усреднения за предыдущие циклы с доверительными интервалами

5. ОБСУЖДЕНИЕ РЕЗУЛЬТАТОВ

Рассмотренный в данной работе метод имеет своей целью прогноз динамики SSN внутри цикла, основываясь на уменьшении степеней свободы предсказания, как целого, что повысило устойчивость и, как представляется, корректность нахождения решения на основе использования классической рекуррентной ИНС, в нашем случае ИНС Элмана. В частности, введение нормализованного пространства представления данных, в отличие от других подходов в применении ИНС к долгосрочному предсказанию СА, позволило построить функцию, имеющую явную асимметрию восходящей и спадающей ветвей внутри цикла и, в какой-то степени, отражающей особенности хода предыдущих циклов. Сравнение прогнозных кривых SWPC (рис. 5) и полученной в [7] методом глубинного обучения многослойной (Deep Learning Methods) нейронной сети (с двумя скрытыми слоями нейронов, но без обратной связи, рис. 6) показывает их большое сходство и очень слабую асимметрию ветвей внутри цикла. Практически она отсутствует, что плохо согласуется с общими представлениями о периодическом характере солнечной активности [1]. Что касается максимума 25-го цикла, то результаты предсказаний сильно расходятся – от очень малых ~ 80 (применение методики [10]) до больших значений в ~ 160 , что отражает сложность связи внутрисолнечных процессов и SSN [15] и, неоднозначность результатов прогнозирования на одних и тех же данных. Так метод глубинного обучения многослойной нейронной сети прямого распространения [7] дает оценку максимума СА представленной числом SSN в 106 единиц и локализацию этого максимума СА во времени на 2025 год. В работе [9], на основе нелинейного динамического анализа данных, максимум оценивается в 154 и ожидается в начале 2023 г. (2023.02), что в, какой-то мере, соответствует результату нашего анализа (2023.10) [16] и рис. 5.

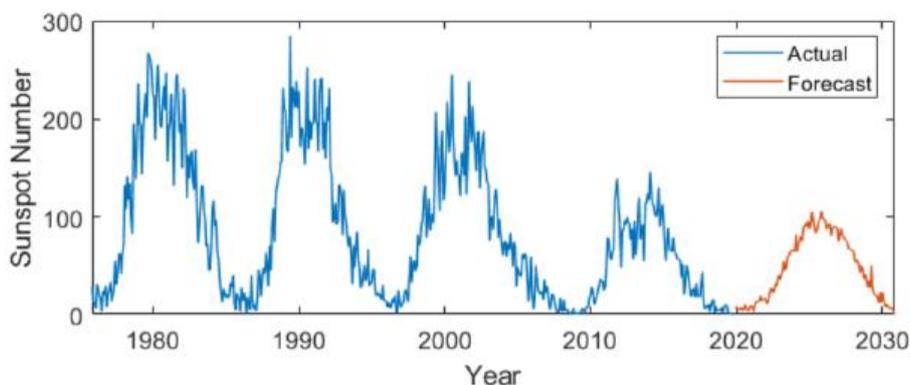


Рис. 6. Прогноз для числа среднемесячных данных по солнечным пятнам на 25-й цикл солнечной активности (метод глубокой нейронной сети – deep neural networks)

Предлагаемый метод анализа временного ряда SSN на основе ИНС имеет высокую степень математической формализации и может быть основой как для долгосрочного прогнозирования в масштабе цикла, так и для интервала в 2-3 года, используя соотношение общего и частного. Как представляется, в обоих случаях имеется возможность подстраивания (адаптации) под ежемесячно поступающие данные регистрации СА, варьируя значения амплитуды A_0 и длительности T_0 прогнозируемого цикла в небольших интервалах изменений. Критерием является достижение минимальных отклонений расчетных и экспериментальных данных в статическом и динамическом режимах работы. Программная реализация метода выполнена на независимой от коммерческих математических пакетов основе и может совершенствоваться по мере практического применения.

6. ЗАКЛЮЧЕНИЕ

Таким образом, на основе рекуррентной ИНС Элмана показана возможность долгосрочного прогнозирования на масштабе цикла солнечной активности временной функции числа солнечных пятен в цикле, применяя метод нормализации исходного временного ряда данных. Предложенный подход, основанный на уменьшении размерности задачи имеет достаточно большую устойчивость и

эффективность прогнозирования, показанную на примере предыдущих четырех циклов, с 21-го по 24-й. Построенный прогноз на 25-й цикл солнечной активности имеет более высокую степень соответствия текущим солнечным данным, имеющимися на вторую половину 2022 г., чем прогноз службы SWPC. В целом, метод можно рассматривать как основу для долгосрочного прогнозирования числа солнечных пятен в интервале 2-4 лет и на масштабе цикла в качестве индексов космической погоды, в частности, в задачах планирования работы радиотехнических систем, использующих ионосферное распространение радиоволн.

ЛИТЕРАТУРА

1. Podladchikova, T., Van der Linden, R. A Kalman Filter Technique for Improving Medium-Term Predictions of the Sunspot Number // *Sol. Phys.* V. 277. P. 397—416. 2012..
2. Macpherson K. Neural network computation techniques applied to solar activity prediction // *Advance in Space Research.* 13(9). P. 375–450, 1993.
3. Fessant F., Bengio S. and Collobert D. On the prediction of solar activity using different neural network models // *Annales Geophysicae*, 14(1). P. 20–26, 1996.
4. Pesnell, W.D. Solar cycle predictions (invited review) // *Solar Phys.* 281(1), 507. DOI: 10.1007/s11207-012-9997-5. 2012.
5. Бархатов Н.А., Королёв А.В., Пономарев С.М., Сахаров С.Ю. Долгосрочное прогнозирование индексов солнечной активности методом искусственных нейронных сетей // *Изв. ВУЗов. Радиофизика.* Т. XLIV. № 9. С. 806-814. 2001.
6. Pala, Z., Atici, R. Forecasting Sunspot Time Series Using Deep Learning Methods. *Sol Phys* 294, 50 (2019). <https://doi.org/10.1007/s11207-019-1434-62019>
7. Benson B., Pan W.D., Prasad A., Gary G.A., Hu Q. Forecasting Solar Cycle 25 Using Deep Neural Networks // *Solar Phys.*, 295:65, <https://doi.org/10.1007/s11207-020-01634-y>, 2020.
8. Sello S. Solar cycle forecasting: a nonlinear dynamics approach // *Astronomy and Astrophysics*, 377. P. 312–320. 2001.
9. Sarp V., Kilcik A., Yurchyshyn V., Rozelot J. P., Ozguc A. Prediction of solar cycle 25: a non-linear approach // *MNRAS* 481, 2981–2985, 2018.
10. Thompson, R. J. A Technique for Predicting the Amplitude of the Solar Cycle // *Solar Physics.* V. 148. Issue 2. P. 383-388. 1993.
11. Hathaway D.H., Wilson R.M. Geomagnetic activity indicates large amplitude for sunspot cycle 24, *Geophysical Research Letters*, 33(L18101). 2006.
12. Elman J.L Finding structure in time // *Cogn. Sci.*, 14. P. 179-211. DOI: 10.1207/s15516709cog1402_1. 1990.
13. Головки В.А. Нейронные сети: обучение, организация и применение // М: ИПРЖР. 255 с. 2001.
14. Головки В.А., Краснопрошин В.В. Нейросетевые технологии обработки данных // Классическое университетское издание, Минск: БГУ. 263 с. 2017.
15. Nandy D., Martens P.C.H., Obridko V., Dash S., Georgieva K. Solar evolution and extrema: current state of understanding of long-term solar variability and its planetary impacts // *Space Science Reviews*, V. 217, Issue 3, article id.39 DOI: 10.1007/s11214-021-00799-7. 2021.
16. Крашенинников И.В., Чумаков С.О. Метод ИНС в задаче долгосрочного прогнозирования индексов солнечной активности // *Физика плазмы в солнечной системе.* 17-я ежегодная конференция. Москва, ИКИ РАН, 7-11 февраля. С. 241. 2022.

PREDICTION OF THE SUNSPOT NUMBER FUNCTION IN THE SOLAR CYCLE BASED ON THE ARTIFICIAL NEURAL NETWORK METHOD

Krasheninnikov I.V., Chumakov S.O.

Possibility of predicting the sunspot number (SSN) function in the solar activity cycle based on the application of the Elman artificial neural network (ANN) platform to the historical row of observational data is analyzed. We propose a method for normalization of the initial data - construction of virtual idealized cycles, using scaled coefficients on the time and values of maxima in the solar activity cycles. The ANN method correctness is analyzed in numerical simulations of the SSN time series. The intervals of variation for the governing parameters in the neural network application were estimated, and a mathematical criterion for choosing a solution is proposed. A characteristic property of the constructed sunspot number function is the significant asymmetry of ascending and descending branches within the cycle. The forecast of the time course for the current 25th solar activity cycle is presented, and its general correctness in comparison with the existing results of solar activity forecasting is discussed.

KEYWORDS: NUMBER OF SUNSPOTS, SSN, LONG-TERM PREDICTION, SOLAR CYCLE, ARTIFICIAL NEURAL NETWORK