

УДК 551.510.5373

ПРОГНОЗИРОВАНИЕ ГЕОМАГНИТНЫХ БУРЬ НА ОСНОВЕ НЕЙРОСЕТЕВОЙ ЦИФРОВОЙ ОБРАБОТКИ СОВМЕСТНЫХ НАБЛЮДЕНИЙ МЮОННОГО ГОДОСКОПА УРАГАН И СТАНЦИЙ НЕЙТРОННЫХ МОНИТОРОВ

© 2022 г. В. Г. Гетманов^{1, 2, *}, В. Е. Чинкин^{1, **}, Р. В. Сидоров^{1, ***},
А. Д. Гвишиани^{1, 2, ****}, М. Н. Добровольский^{1, *****}, А. А. Соловьев^{1, 2, ****},
А. Н. Дмитриева^{1, 3, ****}, А. А. Ковыляева^{1, 3, ****}, И. И. Яшин^{1, 3, ****}

¹Геофизический центр РАН, г. Москва, Россия

²Институт физики Земли им. О.Ю. Шмидта РАН, г. Москва, Россия

³Национальный исследовательский ядерный университет “МИФИ”, г. Москва, Россия

*e-mail: vgetm2015@yandex.ru

**e-mail: v.chinkin@gcras.ru

***e-mail: r.sidorov@gcras.ru

****e-mail: adg@wdcb.ru

*****e-mail: m.dobrovolsky@gcras.ru

*****e-mail: a.soloviev@gcras.ru

*****e-mail: ANDmitriyeva@mephi.ru

*****e-mail: AAKovylyeva@mephi.ru

*****e-mail: IYashin@mephi.ru

Поступила в редакцию 13.10.2021 г.

После доработки 21.01.2022 г.

Принята к публикации 30.03.2022 г.

Предложен метод прогнозирования геомагнитных бурь, основанный на нейросетевой цифровой обработке совместных наблюдений мюонного годоскопа УРАГАН и международной системы станций нейтронных мониторов; использовались временные ряды *Dst*-индексов. Разработаны формулы экстраполяции модельных оценок *Dst*-индексов. Была применена полносвязная нейронная сеть прямого распространения. Реализовано правило принятия решений по прогнозированию. Сформированы оценки вероятностных характеристик прогнозирования геомагнитных бурь. Экспериментальное исследование метода прогнозирования подтвердило его эффективность. Показано, что наблюдения системы годоскоп–мониторы повысили вероятность правильного прогнозирования геомагнитных бурь по сравнению с использованием каждого из видов наблюдений по отдельности.

DOI: 10.31857/S0016794022040083

1. ВВЕДЕНИЕ

Геомагнитные возмущения возникают обычно при экстремальных событиях в гелиосфере, которые являются следствием плазменных образований в виде солнечных корональных выбросов масс (СМЕ — Coronal Mass Ejection). Геомагнитными бурями (ГМБ) принято считать геомагнитные возмущения, имеющие амплитуды больше заданной. Прогнозирование ГМБ представляет собой актуальную научную проблему, которая к настоящему времени не решена исчерпывающим образом.

Геомагнитная активность характеризуется различными геомагнитными индексами, среди

которых являются достаточно распространенными *k*-, *kp*- и *ap*-индексы [Menvielle et al., 2011]. Данная статья основана на применении часто используемых в практике геомагнетизма *Dst*-индексов [Sugiura and Kamei, 1991]. Эти индексы, измеряемые в нанотеслах (нТл), определяются почасовым усреднением значений меридиональных составляющих геомагнитного поля для магнитных обсерваторий, расположенных по экватору Земли. Для спокойных состояний магнитосферы *Dst*-индексы принимают, в основном, значения в пределах $-50...+20$ нТл; для ГМБ *Dst*-индексы принимают значения в диапазоне $-150...-50$ нТл и в исключительных случаях выходят за указанный диапазон.

В статье используется информация из следующих источников:

1. Временной ряд матричных наблюдений из базы данных [Real-time URAGAN, 2015] мюонного годоскопа (Muon Hodoscope – МН) УРАГАН, сконструированного в МИФИ [Yashin et al., 2015]. Здесь рассматривается один из возможных вариантов упрощения решения задачи прогнозирования ГМБ, который состоит в том, что временной ряд матричных наблюдений мюонного годоскопа преобразуется в скалярный временной ряд, полученный посредством усреднения матриц МН-наблюдений. Указанный временной ряд образуют величины МН-наблюдений, пропорциональные интенсивности потоков мюонов, регистрируемых годоскопом УРАГАН. Матричные временные ряды МН-наблюдений для прогнозирования ГМБ станут предметом исследований в следующих публикациях.

2. Временной ряд скалярных наблюдений международной системы станций нейтронных мониторов (Neutron Monitor – NM) [NMDB, 2021]. Здесь используются функции изотропных составляющих NM-наблюдений, полученные на основе метода глобальной съемки [Абунина и др., 2018]. Данный временной ряд образуют величины NM-наблюдений, пропорциональные интенсивности потоков нейтронов, регистрируемых нейтронными мониторами.

3. Временной ряд скалярных *Dst*-индексов на сайте WDCG – World Data Center of Geomagnetism, Kyoto [World Data Center, 2021].

Прогнозирования ГМБ определяются видом используемых информационных источников, применяемой аппаратурой, математических методов и вариантами реализуемых прикладных задач. Существует целый ряд служб различной ведомственной и государственной принадлежности, которые публикуют информацию по прогнозированию ГМБ.

Для РФ следует отметить Центр прогнозирования космической погоды ИЗМИРАН [Гайдаш и др., 2016; Центр прогнозов, 2016; Gaidash et al., 2017], который выдает потребителям более 20 видов продуктов, связанных с прогнозированием космической погоды и ГМБ, в том числе: 3-х суточный прогноз трехчасовых *k*- и *kp*-индексов, 8-ми суточный геомагнитный прогноз на основе среднесуточных *ap*-индексов и вероятностей наибольших *kp*-индексов в сутках, прогноз геомагнитной активности на основе *ap*-индексов на 55 сут вперед и т.д.

Заметной является деятельность Лаборатории рентгеновской астрономии ФИАН в решении проблемы прогнозирования ГМБ с привлечением технологий солнечной радиографии. На сайте [Лаборатория рентгеновской, 2017] приводятся вычисления *kp*-индексов на 3-х дневный и 27-днев-

ный интервалы прогнозирования, которые осуществляются с учетом оценок параметров солнечного ветра.

Необходимо упомянуть подразделение Space Weather Prediction Center NOAA (National Oceanic and Atmospheric Administration, США) [NOAA/NWS, 2021], занимающееся вариантами прогнозирования ГМБ. На сайте NOAA помещаются данные по *kp* и *ap*-индексам для 1–4-х недельных интервалов прогнозирования. Для решения задач прогнозирования ГМБ используются снимки ультрафиолетового телескопа EIT (Extreme Ultraviolet Imaging Telescope) и солнечного коронографа LASCO (Large Angle and Spectrometric Coronagraph) [NOAA/NWS, 2021], с помощью которых оцениваются характеристики нагрева солнечной короны и процессы в СМЕ, а также определяется влияние короны на солнечный ветер. Изображения LASCO используются для прогнозирующей модели WSA-Enlil [NOAA/NWS, 2021], которая действует с 2011 г. Эта крупномасштабная физическая модель гелиосферы предназначена для обеспечения заблаговременного предупреждения за 1–4 дня об изменениях в структурах солнечного ветра и направлений движений СМЕ. Используется космический аппарат (КА) ACE (Advanced Composition Explorer, USA) [NOAA/NWS, 2021], запущенный в 1997 г., постоянно находящийся в точке Лагранжа, расположенной на расстоянии 1.44 млн км от Земли на прямой, соединяющей Землю и Солнце. Данный КА, который можно принять в качестве патрульного, непрерывно регистрирует параметры солнечного ветра и межпланетного магнитного поля и автоматически передает их на Землю; зарегистрированные параметры размещаются на веб-сайтах NOAA для принятия последующих оперативных решений.

Прогнозирование ГМБ может реализовываться на основе целого ряда методов, например, с применением вероятностных моделей или распознаванием аномалий во временных рядах. Так, в статьях [Добровольский и др., 2019; Chinkin et al., 2019] для матричных МН-наблюдений предлагается применение специальных двумерных функций вариаций мюонных потоков и индикаторных матриц.

Нейронные сети (Neural Networks – NN) широко используются в солнечно-земной физике в задачах прогнозирования (распознавания) экстремальных событий в гелиосфере и магнитосфере [Бархатов и Ревунов, 2010]. Целый ряд публикаций, связанных с NN, *Dst*-индексами и ГМБ, отличаются вариантами применяемых методов, программных продуктов и используемых информационных источников (баз данных). Указанные обстоятельства вносят значительные разнообразия в постановки задач.




Рис. 1. Графики фрагментов исходных МН и NM-наблюдений $Y_M(k)$, $Y_N(k)$ и Dst -индексов $Y_D(k)$.

В публикациях [Бархатов и др., 2001; Ефиторов и др., 2018; Широкий, 2015; Dolenko et al., 2005; Gruet et al., 2018; Pallochia et al., 2006; Stepanova and Pérez, 2000; Wu and Lundstedt, 1997] помещены материалы, касающиеся исследований возможностей прогнозирования ГМБ, реализуемых с помощью вариантов NN.

Целью данной работы является разработка метода прогнозирования ГМБ, базирующегося на моделях Dst -индексов, совместном использовании МН и NM-наблюдений, технологии экстраполяции и применения NN. Предлагаемая постановка в некоторых деталях может считаться дополнительной по отношению к перечисленным публикациям. Полученные в статье результаты по прогнозированию ГМБ на основе нейросетевых модельных оценок Dst -индексов с экстраполяцией предназначены для целого ряда научных и технических приложений, например, при возможном внезапном отсутствии (пропуске) Dst -индексов, прогнозирование ГМБ может быть реализовано на основе заранее построенных моделей Dst -индексов, работающих только на основе МН и NM-наблюдений. Предлагаемое прогнозирование ГМБ может оказаться альтернативным при возможных сбоях работы патрульного КА.

2. АНАЛИЗ DST -ИНДЕКСОВ И МН, NM-НАБЛЮДЕНИЙ

Все переменные, которые использовались для NN в рамках данной статьи, были синхронизированы и подвергнуты дискретизации часовым шагом в единой шкале времени UTC. Временной индекс k определял моменты дискретизации Tk ,

$T = 1$ ч. Dst -индексы $Y_D(k)$ и NM-наблюдения $Y_N(k)$ реализовывались на интервале времени 01.01.2002–31.12.2018, МН-наблюдения $Y_M(k)$ – на интервале 01.01.2008–31.12.2018. Начальный и конечный индексы для Y_D принимали значения $k_0 = 1$, $k_f = 149016$, для Y_M – индексы $k_{01} = 52285$, $k_f = 149016$, для Y_N – $k_{02} = 1$, $k_f = 149016$.

На рисунке 1 помещены примеры графиков фрагментов исходных переменных $Y_D = Y_D(k)$, $Y_M = Y_M(k)$ и $Y_N = Y_N(k)$ для шестимесячного временного интервала 01.04.2012–30.09.2012 в зависимости от времени Tk . ГМБ-события определялись неравенством $Y_D(k) \leq Y_{D0}$. Для порога $Y_{D0} = -50$ нТл на данном интервале имели место 9 ГМБ-событий. Анализ $Y_D(k)$ на рис. 1 позволил сделать вывод, что средняя продолжительность ГМБ составила величину порядка 2–2.5 сут. Рассмотрение исходных переменных дало возможность заключить, что для них средний период аддитивных неинформативных низкочастотных трендов, подлежащих фильтрации, составил величину примерно 60–75 сут. На рисунке 1 неинформативные тренды $Y_{D\Phi 0}(k)$, $Y_{M\Phi 0}(k)$ и $Y_{N\Phi 0}(k)$ показаны плавными линиями.

Видно из графиков, что переменные $Y_D(k)$ и $Y_N(k)$ можно представить в виде суммы информативных низкочастотных трендов и высокочастотных шумов. Переменную $Y_M(k)$ можно представить в виде суммы информативного низкочастотного тренда, помеховых составляющих от суточных колебаний и высокочастотных шумов. Анализ изменений информативных низкочастотных трендов переменных $Y_M(k)$, $Y_N(k)$ позволил сделать

вывод об их, в ряде случаев, почти одинаковом поведении во времени.

3. ПОСТАНОВКА ЗАДАЧИ ПРОГНОЗИРОВАНИЯ ГМБ

В практике анализа геомагнитных наблюдений, иногда принято делать заключение о прогнозировании ГМБ по критериям, которые формируются на основе различных вариантов геомагнитных индексов. Достаточно распространенным и, в определенной степени, надежным при прогнозировании ГМБ является критерий, основанный на сравнении *Dst*-индексов с задаваемым порогом. Однако иногда непосредственное использование *Dst*-индексов для прогнозирования может оказаться проблематичным в связи с возможным их отсутствием в текущий и последующие моменты времени, по различным причинам.

Между *Dst*-индексами и величинами МН, MN-наблюдений имеет место вполне определенная функциональная связь, которая может быть представлена модельной схемой на основе [Borog, 2008]. Функции *Dst*-индексов выполняют роль индикаторов ГМБ и их величины определяют интенсивность взаимодействия образований СМЕ с магнитосферой Земли. Время движения СМЕ от Солнца до Земли и время возникновения ГМБ, если его отсчитывать от момента выброса СМЕ, обычно составляет 1.5–2 сут. Одновременно СМЕ модулируют интенсивности потоков релятивистских протонов, направляющихся к Земле; время их движения от Солнца к Земле составляет порядка 8 мин. Потоки протонов вступают в ядерные реакции с атомами веществ верхних слоев атмосферы, в результате этих реакций образуются потоки мюонов и нейтронов, интенсивность которых регистрируется годоскопом УРАГАН и нейтронными мониторами. Модуляции интенсивностей потоков протонов при определенных условиях, вызывают модуляции интенсивностей образовавшихся потоков мюонов и нейтронов – величин МН, MN-наблюдений. Возникновение модуляций потоков мюонов и нейтронов происходит по времени существенно раньше возникновения ГМБ; данное обстоятельство положено в основу предлагаемого метода прогнозирования ГМБ.

Будем полагать, что:

– задан рассматриваемый текущий момент времени, которому соответствует временной индекс k , удовлетворяющий неравенствам $k_{j0} + 1 \leq k \leq k_f$. Предшествующими моментами времени будем считать моменты, которым соответствуют временные индексы $k_{j0} + 1, \dots, k - 1$, где k_{j0} – заданный временной индекс; начальный индекс k_0 , конечный индекс k_f и заданный индекс k_{j0} связаны неравенствами $k_0 < k_{j0} < k_f$.

– на интервале $k_{01} \leq k \leq k_{j0}$ реализован временной ряд МН-наблюдений и временной ряд *Dst*-индексов, в интервале $k_{02} \leq k \leq k_{j0}$ – временной ряд NM-наблюдений и временной ряд значений *Dst*-индексов.

– на интервале $k_{j0} + 1, k - 1, k$ реализованы только временные ряды МН и NM-наблюдений;

Прогнозирование ГМБ будем рассматривать относительно текущих моментов времени с индексами k на k_e индексов вперед.

Цель работы состоит в том, чтобы на основе реализованных временных рядов *Dst*-индексов и МН, NM-наблюдений на интервалах $k_{01} \leq k \leq k_{j0}$, $k_{02} \leq k \leq k_{j0}$ сформировать на интервале $k_{j0} + 1 \leq k \leq k_f$ систему модельных оценок *Dst*-индексов и использовать их для прогнозирования ГМБ. Для данной задачи применим полносвязную NN прямого распространения и технологию экстраполяции при формировании модельных оценок *Dst*-индексов.

4. ОБЩИЙ ПЛАН РЕШЕНИЯ ЗАДАЧИ ПРОГНОЗИРОВАНИЯ ГМБ И ФОРМУЛЫ ЭКСТРАПОЛЯЦИИ

4.1. Общий план решения задачи прогнозирования ГМБ с учетом формулировки в п. 3 постановки подразделяется на пять пунктов, включающих:

1. Алгоритмы предварительной цифровой обработки исходных *Dst*-индексов и МН, NM-наблюдений для выделения в них существенных информативных составляющих;
2. Алгоритмы обучения и валидации NN;
3. Алгоритм экстраполяции МН, NM-наблюдений;
4. Алгоритм тестирования – вычисления модельных оценок *Dst*-индексов с экстраполяцией на основе NN с использованием экстраполированных МН, NM-наблюдений;
5. Алгоритм правила принятия решений для прогнозирования ГМБ.

На рисунке 2 представлена схема вычислительных операций, которая поясняет решение задачи прогнозирования ГМБ. Вычислительные операции подразделены на: блок 1 предварительной цифровой обработки; блоки 2.1, 3.1 обучения МН, NM-нейронной сети; блоки 4, 5 экстраполяции; блоки 2.2, 3.2 вычисления модельных оценок *Dst*-индексов для МН, NM; блок 6 принятия решений по прогнозированию ГМБ.

Алгоритмы предварительной цифровой обработки для исходных *Dst*-индексов $Y_D = Y_D(k)$ и МН, NM-наблюдений $Y_M = Y_M(k)$, $Y_N = Y_N(k)$ реализуют их фильтрацию [Filter Design, 2021] с целью устранения высокочастотных шумов и суточных колебаний, удаление низкочастотных неинформативных трендов и масштабирование для




Рис. 2. Схема вычислительных операций решения задачи прогнозирования ГМБ.




Рис. 3. Графики переменных $Y_{MP}(k)$, $Y_{NP}(k)$ и $Y_{DP}(k)$, полученных в результате предварительной цифровой обработки на месячном интервале.

обеспечения соизмеримости исходных переменных, которая необходима для эффективной работы NN.

Результаты предварительной цифровой обработки обозначаются как $Y_{DC} = Y_{DC}(k)$, $Y_{MC} = Y_{MC}(k)$ и $Y_{NC} = Y_{NC}(k)$. Операция масштабирования приводит результаты предварительной обработки к единому диапазону: $Y_{\min} \leq Y_{MC}(k) \leq Y_{\max}$, $Y_{\min} \leq Y_{NC}(k) \leq Y_{\max}$, $Y_{\min} \leq Y_{DC}(k) \leq Y_{\max}$, $Y_{\min} = 0.7$, $Y_{\max} = 1.3$. На рис. 3 представлены примеры графиков фрагментов переменных $Y_{MC} = Y_{MC}(k)$, $Y_{NC} = Y_{NC}(k)$ и $Y_{DC} = Y_{DC}(k)$, полученных в результате предварительной цифровой обработки на месячном интервале времени 01.04.2012–30.04.2012.

Этап обучения NN для переменных МН $Y_{MC1}(k)$ реализуется на интервале с индексами

$k_{01} + dk_{01} + 1 \leq k \leq k_{f0}$, для переменных NM $Y_{NC1}(k)$ – на индексах $k_{02} + dk_{02} + 1 \leq k \leq k_{f0}$, на указанных интервалах реализуются переменные $Y_{DC}(k)$. Величины dk_{01} , dk_{02} задаются. На вход NN подаются скользящие с единичным шагом последовательности векторов размерности Δk , образованные указанными переменными. Этап валидации нейросетевых моделей после обучения для переменных МН осуществляется для индексов $k_{01} \leq k \leq k_{01} + dk_{01}$, для переменных NM на индексах $k_{02} \leq k \leq k_{02} + dk_{02}$. В результате этапов обучения и валидации производятся формирования МН, NM-нейросетевых моделей для Dst -индексов. Этап тестирования отводится для вычислений модельных Dst -индексов на основе нейросетевых моделей на интервале с индексами $k_{f0} + 1 \leq k \leq k_f$.




Рис. 4. Графики переменных $Y_{MP2}(k)$, $Y_{NP2}(k)$, полученных в результате операций фильтрации и масштабирования на 4-х дневном интервале 01.04.2012–04.04.2012 г.

Для тестирования реализуется алгоритм экстраполяции над переменными $Y_{MC2}(k)$ и $Y_{NC2}(k)$ с целью последующего использования экстраполяций в сформированных нейросетевых моделях.

На рисунке 4 приведены примеры графиков переменных $Y_{MC} = Y_{MC2}(k)$, $Y_{NC} = Y_{NC2}(k)$, полученных в результате фильтрации и масштабирования на 4-х дневном интервале 01.04.2012–04.04.2012 и подготовленных для экстраполирования. Можно заключить, что переменные $Y_{MC2}(k)$, $Y_{NC2}(k)$ хорошо приспособлены для реализации экстраполирования: видно, что вполне допустима их успешная экстраполяция на основе параболических функций по крайней мере на $k_e = 5$ –10 шагов вперед.

4.2. Формулы экстраполяции реализуются на основе построения аппроксимационных параболических моделей относительно текущего индекса k ; назначается параметр экстраполяции k_e – количество шагов экстраполяции $k + 1, k + 2, \dots, k + k_e$. Задается k_a – количество индексов на интервале $k, k - 1, \dots, k - k_a + 1$, на котором предполагается производить построение аппроксимационной модели. Формируются аппроксимационные параболические функции с параметрами $c_1^T = (c_{01}, c_{11}, c_{21})$, $c_2^T = (c_{02}, c_{12}, c_{22})$ и аппроксимационные функционалы

$$F(c_1, Y_{MC2}, k_a, k) = \sum_{s=k-k_a+1}^k (Y_{MC2}(s) - c_{01} - c_{11}s - c_{21}s^2)^2,$$

$$F(c_2, Y_{NC2}, k_a, k) = \sum_{s=k-k_a+1}^k (Y_{NC2}(s) - c_{02} - c_{12}s - c_{22}s^2)^2.$$

Находятся оптимальные параметры аппроксимационных моделей путем минимизации введенных функционалов

$$c_1^{\circ} = \arg\{\min_{c_1} F(c_1, Y_{MP2}, k_a, k)\},$$

$$c_2^{\circ} = \arg\{\min_{c_2} F(c_2, Y_{NP2}, k_a, k)\}.$$

Экстраполированные модели $\bar{Y}_{MC2} = \bar{Y}_{MC2}(k, k_e)$, $\bar{Y}_{NC2} = \bar{Y}_{NC2}(k, k_e)$ образуются на скользящих с единичным шагом интервалах размерности Δk . Для k_e индексов $k + 1, k + 2, \dots, k + k_e$ экстраполированные модели представляются аппроксимационными параболическими функциями

$$\begin{aligned} \bar{Y}_{MC2}(k, k_e) &= c_{01}^{\circ} + c_{11}^{\circ}k + c_{21}^{\circ}k^2, \\ \bar{Y}_{NC2}(k, k_e) &= c_{02}^{\circ} + c_{12}^{\circ}k + c_{22}^{\circ}k^2. \end{aligned} \quad (1)$$

Для $\Delta k - k_e$ индексов $k + k_e - \Delta k + 1, k + k_e - \Delta k + 2, \dots, k$, экстраполированные модели представляются формулами

$$\begin{aligned} \bar{Y}_{MC2}(k, k_e) &= \bar{Y}_{MC2}(k), \\ \bar{Y}_{NC2}(k, k_e) &= \bar{Y}_{NC2}(k). \end{aligned} \quad (2)$$

Вычисления скользящих экстраполированных модельных оценок Dst -индексов осуществляются с помощью нейросетевых моделей для экстраполированных МН, NM-наблюдений $\bar{Y}_{DM} = \bar{Y}_{MC2}(k, k_e)$,




Рис. 5. Архитектура нейронной сети.

$\bar{Y}_{DN} = \bar{Y}_{NC2}(k, k_e)$ на интервале $k_{1T} \leq k \leq k_{2T}$. Для вычисления k_{1T}, k_{2T} записываются следующие неравенства, вытекающие из (1)–(2),

$$k_{f0} + 1 \leq k + k_e - \Delta k + 1, \quad k + k_e \leq k_f.$$

Решение указанных неравенств позволяет определить граничные индексы

$$k_{1T} = k_{f0} - k_e + \Delta k, \quad k_{2T} = k_f - k_e. \quad (3)$$

Алгоритм правила принятия решений для прогнозирования ГМБ основывается на вычисленных скользящих экстраполированных модельных оценках Dst -индексов $\bar{Y}_{DM}, \bar{Y}_{DN}$ и сравнении их с задаваемым порогом Y_{D0} . Принятие решений о прогнозировании ГМБ реализуется на интервале $k_{1T} \leq k \leq k_{2T}$ (3).

5. АРХИТЕКТУРА НЕЙРОННОЙ СЕТИ

Результаты, полученные выше, основываются на полносвязной NN прямого распространения, сформированной с использованием универсального программного продукта [Deep Learning, 2021]. Применение NN этого типа обуславливается тем, что исходные данные и наблюдения в данном случае представляют собой скалярные временные ряды.

Архитектура используемой NN представлена на рис. 5. Были реализованы 4 слоя (CL – Connected Layer) с входными переменными Y_{DC}, Y_{MC1}, Y_{NC1} , на основе которых формировались входные последовательности векторов размерности Δk . Использовались функции активации $f(x) = 1, x > 0$, $f(x) = 0, x \leq 0$. Выходы от четырех слоев CL1–CL4 подавались на суммирующий полносвязный слой (FCL – Fully Connected Layer). Выходом NN на этапе обучения являются сформированные нейросетевые модели.

Индексы интервалов исходных переменных принимали численные значения в соответствии с п.2 и были назначены $dk_{01} = 12000$, $dk_{02} = 15000$. Назначался индекс $k_{f0} = 131810$, соответствующий дате 01.01.2017 г., определявший 8-ми летний интервал обучения 01.01.2008–31.12.2016 для МН и 14-ти летний интервал 01.01.2002–31.12.2016 для NM. 2-х летний интервал 01.01.2017–31.12.2018 отводился на вычисления модельных оценок Dst -

индексов на основе МН, NM-наблюдений с использованием нейросетевых модельных структур.

6. ПРАВИЛО ПРИНЯТИЯ РЕШЕНИЙ ПО ПРОГНОЗИРОВАНИЮ ГМБ

Метод прогнозирования ГМБ сведем к процедуре классификации [Фомин, 2010; Bishop, 2006], основанной на сравнении экстраполированных модельных оценок Dst -индексов с задаваемым порогом для текущего индекса k с учетом шагов экстраполяции k_e .

Сформируем правило принятия решений о прогнозировании ГМБ на основе совместного использования МН, NM-модельных оценок Dst -индексов, которое состоит в том, что если будет выполняться хотя бы одно или оба условия для текущего индекса k

$$\bar{Y}_{DM}(k, k_e) \leq Y_{D0} \quad \text{и/или} \quad \bar{Y}_{DN}(k, k_e) \leq Y_{D0}, \quad (4)$$

$$k_{1T} \leq k \leq k_{2T},$$

то будем принимать решение по прогнозированию ГМБ для индекса $k + k_e$; в остальных случаях будем принимать противоположное решение.

Сделаем пояснения по поводу реализации прогнозирования. Положим, что возможная ГМБ реализовывалась на временном интервале с индексами, которые удовлетворяли неравенствам $k_{GS1} \leq k \leq k_{GS2}$. По-прежнему будем считать, что прогнозирование осуществляется для момента времени с индексом k на k_e индексов вперед. Рассмотрим два возможных варианта: 1. когда момент k принятия решения по прогнозированию находится вне интервала с ГМБ, 2. когда момент k принятия решения по прогнозированию находится внутри интервала с ГМБ. В том случае, даже если в обоих вариантах прогнозирования реализовались, что эквивалентно неравенству $k_{GS1} \leq k_e \leq k_{GS2}$, то эти варианты существенно отличаются. Для первого варианта реализованный вариант является вполне полноценным, поскольку прогнозирование осуществлялось заблаговременно по отношению к ГМБ. Во втором варианте прогнозирование осуществилось, когда ГМБ уже наступила. На рис. 6а, б приводятся прогнозирования по первому и второму вариантам. Первому и вто-




Рис. 6. Первый и второй варианты прогнозирования ГМБ.

рому варианту прогнозирования ГМБ соответствуют следующие неравенства

$$k \leq k_{GS1} \leq k_e \leq k_{GS2}, \quad k_{GS1} \leq k < k_e \leq k_{GS2},$$

7. ВЫЧИСЛЕНИЕ ОЦЕНОК ВЕРОЯТНОСТЕЙ ПРАВИЛЬНОГО И ЛОЖНОГО ПРОГНОЗИРОВАНИЯ ГМБ

Прогнозирование ГМБ, обычно сопровождается погрешностями — пропусками правильных и образованиями ложных прогнозирований. Данные погрешности зависят от вероятностных характеристик переменных $\bar{Y}_{DM}$, $\bar{Y}_{DN}$. Воспользуемся результатами работы [Мерков, 2014; Михайлов и Войтишек, 2006] для их приближенного вычисления. Сформируем оценки вероятностей погрешностей прогнозирования, в которых используем исходные Dst -индексы $Y_D(k)$, модельные оценки прогнозируемых Dst -индексов $\bar{Y}_{DM}(k, k_e)$, $\bar{Y}_{DN}(k, k_e)$, которые являются случайными. Реализуем вычисления для ряда вариантов шагов экстраполяции k_e и используем правило принятия решений (4).

Фиксируем порог Y_{D0} и рассмотрим момент времени с индексом $k + k_e$, в котором имеет место ГМБ, если выполняется неравенство $Y_D(k + k_e) \leq Y_{D0}$. Количество N_{GS} состояний с ГМБ, которые определяются выполнениями данного неравенства на интервале $k_{1T} \leq k \leq k_{2T}$ вычислим с помощью следующей суммы

$$N_{GS} = \sum_{k=k_{1T}}^{k_{2T}} \text{sign}(Y_{D0} - Y_D(k + k_e)), \quad (5)$$

где $\text{sign} x = 1, x \geq 0$, $\text{sign} x = 0, x < 0$. Определим $N_{M,GS}$ — количество правильных прогнозирования ГМБ с помощью $\bar{Y}_{DM}(k, k_e)$, основанных на (4); найдем β_M — оценку вероятности правильных предсказаний

$$N_{M,GS} = \sum_{k=k_{1T}}^{k_{2T}} \text{sign}(Y_{D0} - Y_D(k + k_e)) \times \text{sign}(Y_{D0} - \bar{Y}_{DM}(k, k_e)), \quad \beta_M^\circ = \frac{N_{M,GS}}{N_{GS}}. \quad (6)$$

Подсчитаем количество $N_{N,GS}$ правильных прогнозирования ГМБ с помощью $\bar{Y}_{DN}(k, k_e)$, ис-

пользуя (4), определим оценку вероятности правильного прогнозирования β_N

$$N_{N,GS} = \sum_{k=k_{1T}}^{k_{2T}} \text{sign}(Y_{D0} - Y_D(k + k_e)) \times \text{sign}(Y_{D0} - \bar{Y}_{DN}(k, k_e)), \quad \beta_N^\circ = \frac{N_{N,GS}}{N_{GS}}. \quad (7)$$

Оценку вероятности β_{MN} правильных прогнозирования ГМБ при совместном (4) использовании $\bar{Y}_{DM}(k, k_e)$, $\bar{Y}_{DN}(k, k_e)$ найдем следующим образом

$$N_{MN,GS} = \sum_{k=k_{1T}}^{k_{2T}} \text{sign}[Y_{D0} - Y_D(k + k_e)] \times \text{sign}[\text{sign}(Y_{D0} - \bar{Y}_{DN}(k, k_e)) + \text{sign}(Y_{D0} - \bar{Y}_{DM}(k, k_e))], \quad \beta_{MN}^\circ = \frac{N_{MN,GS}}{N_{GS}}. \quad (8)$$

Количества N_{0GS} , $N_{M,0GS}$, $N_{N,0GS}$, $N_{MN,0GS}$ и вероятности ложных прогнозирования ГМБ α_M° , α_N° , α_{MN}° вычислим по формулам аналогичным (5)–(8). Расчеты по формулам (5)–(8) реализуем для набора шагов экстраполяции k_e . Вероятности пропусков прогнозирования для МН, NM и МН|NM определим разностями $1 - \beta_M^\circ$, $1 - \beta_N^\circ$ и $1 - \beta_{MN}^\circ$.

8. ЭКСПЕРИМЕНТАЛЬНОЕ ИССЛЕДОВАНИЕ МЕТОДА ПРОГНОЗИРОВАНИЯ ГМБ

8.1. Оценивание вероятности правильного и ложного прогнозирования ГМБ в зависимости от шага экстраполяции k_e . На интервале с индексами $k_{1T} \leq k \leq k_{2T}$ был рассмотрен временной ряд $Y_D(k)$ Dst -индексов из базы данных [World Data Center, 2021]. Для заданных целочисленных параметров k_e вычислялись экстраполированные модельные оценки $\bar{Y}_{DM}(k, k_e)$, $\bar{Y}_{DN}(k, k_e)$ и производились их сравнения с порогом Y_{D0} , а также определялись вероятности правильного и ложного прогнозирования ГМБ по формулам (5)–(8) в зависимости от параметра k_e для диапазона $k_{e,min} \leq k_e \leq k_{e,max}$, $k_{e,min} = 0$, $k_{e,max} = 9$ при $Y_{D0} = -50$ нТл.

На рисунке 7а, б представлены графики результатов расчетов оценок вероятностей пра-

вильного прогнозирования β_M° (МН), β_N° (НМ), β_{MN}° (МН|НМ) и вероятностей ложного прогнозирования α_M° (МН), α_N° (НМ), α_{MN}° (МН|НМ) в зависимости от k_e . Из представленных графиков с результатами расчетов видно, что совместное использование МН и НМ-наблюдений повысило эффективность прогнозирования ГМБ. Из рисунка 7а можно заключить, что для параметра прогнозирования $k_e = 5$, вероятность правильного совместного прогнозирования ГМБ принимала максимальное значение и составляла величину $\beta_{MN}^\circ \approx 0.65$ что больше соответствующей величины $\beta_N^\circ \approx 0.57$ на 13–15%. Вероятность ложного совместного прогнозирования, в соответствии с рис. 7б, не превысила величины $\alpha_{MN}^\circ \approx 0.06$.

8.2. Вычисление прогнозов ГМБ на заданном временном интервале. Рассматривался исходный временной интервал с индексами $k_{1T} \leq k \leq k_{2T}$, на котором вычислялись модельные оценки Dst -индексов и решалась задача прогнозирования ГМБ. На этом интервале формировался временной ряд $Y_D(k)$ и для заданных значений параметра экстраполяции k_e вычислялись экстраполированные модельные оценки $\bar{Y}_{DM}(k, k_e)$, $\bar{Y}_{DN}(k, k_e)$.

Рассматривался контрольный интервал с индексами k_{1C}, k_{2C} , которые удовлетворяли неравенствам $k_{1T} < k_{1C} \leq k \leq k_{2C} < k_{2T}$. Определялись последовательности интервалов $k_{GS1} \leq k \leq k_{GS2}$ в которых имели место ГМБ с помощью проверки неравенства для скользящих k и заданного значения параметра экстраполяции k_e

$$Y_D(k + k_e) \leq Y_{D0}, \quad k_{1C} \leq k \leq k_{2C}.$$

Определялись последовательности интервалов $k_{M1} \leq k \leq k_{M2}$ и $k_{N1} \leq k \leq k_{N2}$, в которых реализовывались прогнозирования ГМБ по правилу принятия решений (4) с помощью проверки выполнения неравенств

$$\bar{Y}_{DM}(k, k_e) \leq Y_{D0}, \quad \bar{Y}_{DN}(k, k_e) \leq Y_{D0}.$$

При прогнозировании ГМБ учитывалось взаимное расположение интервалов (k_{GS1}, k_{GS2}) и (k_{M1}, k_{M2}) , (k_{N1}, k_{N2}) . Были введены разности времен Tdk_M , Tdk_N для отдельных наблюдений и разности Tdk_{MN} , где $k_{MN} = \max(k_{M1}, k_{N1})$ для совместных МН, НМ-наблюдений, по которым можно судить об эффективности прогнозирования ГМБ

$$Tdk_M = Tk_{GS1} - Tk_{M1}, \quad Tdk_N = Tk_{GS1} - Tk_{N1}, \\ Tdk_{MN} = Tk_{GS1} - Tk_{MN}.$$

Очевидно, что прогнозирование ГМБ имеет смысл, когда при отдельных и совместных на-




Рис. 7. Оценки β_M° , β_N° , β_{MN}° вероятностей правильного прогнозирования ГМБ – (а). Оценки α_M° , α_N° , α_{MN}° вероятностей ложного прогнозирования ГМБ – (б).

блюдениях выполнялись неравенства $Tdk_M > 0$, $Tdk_N > 0$ и $Tdk_{MN} > 0$.

В зависимости от расположений (k_{GS1}, k_{GS2}) и (k_{M1}, k_{M2}) , (k_{N1}, k_{N2}) , очевидно, возможны реализации правильных прогнозирования (cf – correct forecasting), пропусков правильных прогнозирования (mcf – miss of correct forecasting) и ложных прогнозирования (ff – false forecasting) ГМБ. Чем больше величины введенных разностей, тем в большей степени заблаговременным является прогнозирование ГМБ. Отрицательные значения для dk_M , dk_N , dk_{MN} можно принять соответствующими пропускам прогнозирования – mfc.

Для первого примера рассматривался контрольный временной пятимесячный интервал 01.05.2017–30.09.2017 г.; были использованы $Y_D = Y_D(k)$ и $\bar{Y}_{DM} = \bar{Y}_{DM}(k, k_e)$, $\bar{Y}_{DN} = \bar{Y}_{DN}(k, k_e)$ с $k_e = 5$. На рис. 8а приведены графики для данных переменных. Пунктирной линией отмечен назначенный порог $Y_{D0} = -52.5$ нТл. Результаты вычислений прогнозирования помещены в табл. 1, для экономии места 2017 год в датах пропущен; в столбцах помещены календарные переменные месяц, день, час, полученные на основе преобразования индексов k . В столбцах 2, 3 помещены времена интервалов (Tk_{GS1}, Tk_{GS2}) начала и конца




Рис. 8. Графики переменных $Y_D(k)$, $\bar{Y}_{DM}(k, k_e)$ и $\bar{Y}_{DN}(k, k_e)$, $k_e = 5$ – (а). Графики переменных $Y_D(k)$, $\bar{Y}_{DM}(k, k_e)$ и $\bar{Y}_{DN}(k, k_e)$, $k_e = 7$ – (б).

событий, обусловленные понижениями $Y_D(k)$, которые могут оказаться ГМБ-событиями, первый столбец определял номера N_0 интервалов с ГМБ-событиями. В столбцах 4, 5 и 7, 8 помещены времена интервалов (Tk_{M1}, Tk_{M2}) , (Tk_{N1}, Tk_{N2}) с точностью до часа. Всего реализовалось 5 ГМБ-

событий. Из содержимого столбца 10 со временем прогнозирования $Tdk_e = \max(Tdk_M, Tdk_N)$ можно заключить, что правильные прогнозирование ГМБ были осуществлены в четырех событиях – $N_{cf} = 4$: для № 1 – прогнозирование реализовывалось за 3 ч, № 2 – за 4 ч, № 3 – за 2 ч, № 4 – за 5 ч.

Таблица 1. Экстраполяция $k_e = 5$, 2017 г.

N_0	Tk_{GS1}	Tk_{GS2}	Tk_{M1}	Tk_{M2}	Tdk_M	Tk_{N1}	Tk_{N2}	Tdk_N	Tdk_e
1	05.28.00	05.28.20	—	—	—	05.27.21	05.29.11	+3	+3—cf
2	07.16.12	07.17.17	07.16.21	07.17.17	—5	07.16.08	07.17.21	+4	+4—cf
3	09.07.23	09.10.03	09.08.03	09.08.21	—4	09.07.21	09.10.09	+2	+2—cf
4	09.14.20	09.14.21	—	—	—	09.14.15	09.15.17	+5	+5—cf
5	09.28.01	09.28.13	—	—	—	—	—	—	—mcf

Таблица 2. Экстраполяция $k_e = 7$, 2015 г.

N_0	Tk_{GS1}	Tk_{GS2}	Tk_{M1}	Tk_{M2}	Tdk_M	Tk_{N1}	Tk_{N2}	Tdk_N	Tdk_e
1	08.25.23	08.26.09	08.26.09	08.27.11	–10	08.25.22	08.26.14	+1	+1–cf
2	09.10.18	09.11.20	–	–	–	09.10.11	09.10.21	+7	+7–cf
3	09.22.02	09.22.20	09.22.11	09.22.12	–9	–	–	–9	–9–mcf
4						10.07.18	10.08.12		ff

Для события № 5 имел место пропуск правильно-го прогнозирования – $N_{mf} = 1$. Имело место 0 ложных прогнозирований – $N_{ff} = 0$.

Для второго примера рассматривался контрольный трехмесячный интервал 2015.08.01–2015.10.31 и использованы $Y_D = Y_D(k)$ и $\bar{Y}_{DM} = \bar{Y}_{DM}(k, k_e)$, $\bar{Y}_{DN} = \bar{Y}_{DN}(k, k_e)$ с $k_e = 7$, назначен порог $Y_{D0} = -52.5$ нТл. На рис. 8б изображены соответствующие графики переменных, пунктирной линией отмечен порог. Результаты вычислений помещены в табл. 2. Реализовалось три ГМБ-события в течение рассматриваемого трехмесячного интервала. Из содержимого столбца 10 можно заключить, что правильные прогнозирования ГМБ были осуществлены в двух случаях – $N_{cf} = 2$: для № 1 – прогнозирование реализовывалось за 1 ч, № 2 – за 7 ч. Имело место одно ложное прогнозирование – $N_{ff} = 1$ и один пропуск прогнозирования – $N_{mf} = 1$.

Для приближенного оценивания эффективности метода прогнозирования ГМБ вводились коэффициенты правильных и ложных прогнозирований ϵ_{cf} и ϵ_{ff} , вполне очевидный физический смысл которых вытекает из следующих формул

$$\epsilon_{cf} = N_{cf} / (N_{cf} + N_{mf}), \quad \epsilon_{ff} = N_{ff} / N_{cf}.$$

Вычисление коэффициентов на основе табл. 1 и 2 позволило установить их усредненные значения $\bar{\epsilon}_{cf} \approx 73\%$, $\bar{\epsilon}_{mf} \approx 25\%$, которые можно принять в качестве первых приближений оценок эффективности предложенного метода прогнозирования.

9. ЗАКЛЮЧЕНИЕ

1. Предложенный метод прогнозирования геомагнитных бурь (ГМБ) на основе совместных наблюдений мюонного годоскопа УРАГАН и нейтронных мониторов с применением полносвязной нейронной сети прямого распространения и использованием экстраполированных модельных оценок Dst -индексов, оказался работоспособным.

2. Исследование предложенного метода прогнозирования ГМБ на наблюдениях мюонного годоскопа, нейтронных мониторов и Dst -индек-

сов, полученных за 2008–2018 гг. и 2002–2018 гг., показало его эффективность.

3. Произведенные расчеты совместного использования МН и НМ-наблюдений показали, что для оптимального параметра предсказания $k_e = 5$ оценка вероятности правильного прогнозирования ГМБ составила величину $\beta_{MN}^{\circ} \approx 0.65$, что больше соответствующей величины $\beta_N^{\circ} \approx 0.57$ на 13–15%; вероятность ложного прогнозирования не превышает величины $\alpha_{MN}^{\circ} \approx 0.06$.

4. Рассмотрение примеров экспериментальных данных на пятимесячных интервалах показало возможность предлагаемого метода реализовать коэффициенты правильного и ложного прогнозирования $\approx 73\%$, $\approx 25\%$, что свидетельствует о приемлемых возможностях предложенного метода.

5. Предложенный метод прогнозирования ГМБ имеет большие резервы для усовершенствования, в частности, дальнейшей оптимизации настроек параметров нейронной сети с целью повышения вероятностей правильного и снижения вероятностей ложного прогнозирования.

6. Предложенный метод прогнозирования ГМБ имеет благоприятную перспективу его использования в прикладных задачах геофизики.

9. БЛАГОДАРНОСТИ

Авторы благодарят к. ф.-м. н. Белова А.В., к. ф.-м. н. Янке В.Г. и к. ф.-м. н. Абунина А.А. (ИЗМИРАН) за предоставленную возможность использования специально подготовленных НМ-наблюдений и полезные замечания при подготовке рукописи статьи.

ФИНАНСИРОВАНИЕ РАБОТЫ

Работа выполнена в рамках государственного задания Геофизического центра РАН, утвержденного Министерством науки и высшего образования Российской Федерации.

СПИСОК ЛИТЕРАТУРЫ

– Абунина М.А., Абунин А.А., Белов А.В., Ерошенко Е.А., Оленева В.А., Янке В.Г. Метод глобальной съемки для мировой сети нейтронных мониторов // Геомагнетизм и аэрномия. Т. 58. № 3. С. 374–389. 2018. <https://doi.org/10.7868/S0016794018030082>

- Бархатов Н.А., Ревунов С.Е. Искусственные нейронные сети в задачах солнечно-земной физики. Н. Новгород: Типография “Поволжье”, 407 с. 2010.
- 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. 44. № 9. С. 806–814. 2001.
- Гайдаш С.П., Белов А.В., Абуни А.А., Абунина М.А. Центр прогнозов космической погоды (ИЗМИРАН) / Практические аспекты гелиогеофизики. Материалы специальной секции “Практические аспекты науки космической погоды” одиннадцатой ежегодной конференции “Физика плазмы в солнечной системе”. Москва, 17 февраля 2016 г. Серия “Прикладные аспекты космической погоды”. Ред. А.А. Петрукович, А.М. Мерзлый, С.Ю. Хабибулин. М.: ИКИ РАН. С. 22–32. 2016.
- Добровольский М.Н., Астапов И.И., Барбашина Н.С. и др. Метод поиска локальной анизотропии потоков мюонов в матричных данных годоскопа УРАГАН // Изв. РАН. Сер. физ. Т. 83. № 5. С. 706–708. 2019. <https://doi.org/10.1134/S0367676519050120>
- Ефимов А.О., Мягкова И.Н., Широкий В.Р., Доленко С.А. Прогнозирование *Dst*-индекса, основанное на методах машинного обучения // Космические исследования. Т. 56. № 6. С. 420–428. 2018. <https://doi.org/10.31857/S002342060002493-0>
- Лаборатория рентгеновской астрономии Солнца, ФИАН. <https://tesis.lebedev.ru/>. 2021.
- Мерков А.Б. Распознавание образов: Построение и обучение вероятностных моделей. М.: URSS, 238 с. 2014.
- Михайлов Г.А., Войтишек А.В. Численное статистическое моделирование. Методы Монте-Карло. М.: Академия, 368 с. 2006.
- Фомин Я.А. Распознавание образов: теория и применения. М.: Фазис, 368с. 2010.
- Центр прогнозов космической погоды ИЗМИРАН. <http://spaceweather.izmiran.ru/>. 2016.
- Широкий В.Р. Сравнение нейросетевых моделей прогнозирования геомагнитного *Dst* индекса на различных наборах данных и сравнение методов оценки качества работы моделей / XVII Всероссийская научно-техническая конф. “Нейроинформатика-2015” 19–23 янв. 2015, Москва. Сборник научных трудов. Т. 2. М.: НИЯУ МИФИ. С. 51–60. 2015.
- Bishop C.M. Pattern Recognition and Machine Learning. New York: Springer, 758 p. 2006.
- Borog V.V. Fundamentals of muon diagnostics. Moscow: Moscow Engineering Physics Institute (State University), 160 p. 2008.
- Chinkin V.E., Astapov I.I., Gvishiani A.D., Getmanov V.G., Dmitrieva A.N., Dobrovolsky M.N., Kovylyayeva A.A., Sidorov R.V., Soloviev A.A., Yashin I.I. Method for the Identification of Heliospheric Anomalies Based on the Functions of the Characteristic Deviations for the Observation Matrices of the Muon Hodoscope // Phys. Atom. Nuclei. V. 82. P. 924–928. 2019. <https://doi.org/10.1134/S106377881966013X>
- Deep Learning Toolbox – MATLAB. <https://www.mathworks.com/products/deep-learning.html>. 2021.
- Dolenko S.A., Orlov Y.V., Persiantsev I.G., Shugai J.S. Neural Network Algorithm for Events Forecasting and Its Application to Space Physics Data / Artificial Neural Networks: Formal Models and Their Applications – ICANN 2005. ICANN 2005. / Lecture Notes in Computer Science, 3697. Duch W., Kacprzyk J., Oja E., Zadrozny S. (eds). Berlin, Heidelberg: Springer. P. 527–532. 2005. https://doi.org/10.1007/11550907_83
- Filter Design Using MATLAB. <https://www.mathworks.com/discovery/filter-design.html>. 2021.
- Gaidash S.P., Belov A.V., Abunina M.A., Abunin A.A. Space Weather Forecasting at IZMIRAN // Geomagn. Aeron. V. 57. P. 869–876. 2017. <https://doi.org/10.1134/S0016793217070088>
- Gruet M.A., Chandorkar M., Sicard A., Camporeale E. Multiple-hour-ahead forecast of the *Dst* index using a combination of long short-term memory neural network and Gaussian process // Space Weather. V. 16. № 11. P. 1882–1896. 2018. <https://doi.org/10.1029/2018SW001898>
- Menvielle M., Iyemori T., Marchaudon A., Nosé M. Geomagnetic Indices / Geomagnetic Observations and Models / IAGA Special Sopron Book Series, 5. Manda M., Korte M. (eds) Dordrecht: Springer. P. 183–228. 2011. https://doi.org/10.1007/978-90-481-9858-0_8
- NMDB: the Neutron Monitor Database. <https://www.nmdb.eu/>. 2021.
- NOAA/NWS Space Weather Prediction Center. <https://www.swpc.noaa.gov/>. 2021.
- Pallochia G., Amata E., Consolini G., Marcucci M.F., Bertello I. Geomagnetic *Dst* index forecast based on IMF data only // Ann. Geophys. V. 24. P. 989–999. 2006. <https://doi.org/10.5194/angeo-24-989-2006>
- Real-time URAGAN data. http://nevod.mephi.ru/uragan_data.htm. 2015.
- Stepanova M.V., Pérez P. Autoprediction of *Dst* index using neural network techniques and relationship to the auroal geomagnetic indices // Geofísica Internacional. V. 39. № 1. P. 143–146. 2000. <https://doi.org/10.22201/igeof.00167169p.2000.39.1.310>
- Sugiura M., Kamei T. Equatorial *Dst* index 1957–1986. IAGA Bulletin № 40. Saint-Maur-des-Fossés: ISGI Publications Office. 251 p. 1991.
- World Data Center for Geomagnetism, Kyoto. <http://wdc.kugi.kyoto-u.ac.jp>. 2021.
- Wu J.-G., Lundstedt H. Geomagnetic storm predictions from solar wind data with the use of dynamic neural networks // J. Geophys. Res. V. 102. № A7. P. 14255–14268. 1997. <https://doi.org/10.1029/97JA00975>
- Yashin I.I., Astapov I.I., Barbashina N.S. et al. Real-time data of muon hodoscope URAGAN // Adv. Space Res. V. 56. № 12. P. 2693–2705. 2015. <https://doi.org/10.1016/j.asr.2015.06.003>