

**РАСПОЗНАВАНИЕ ГЕОМАГНИТНЫХ БУРЬ
НА ОСНОВЕ МАТРИЧНЫХ ВРЕМЕННЫХ РЯДОВ НАБЛЮДЕНИЙ
МЮОННОГО ГОДОСКОПА УРАГАН
С ИСПОЛЬЗОВАНИЕМ НЕЙРОННЫХ СЕТЕЙ ГЛУБОКОГО ОБУЧЕНИЯ**

**RECOGNITION OF GEOMAGNETIC STORMS
FROM TIME SERIES OF MATRIX OBSERVATIONS
WITH THE MUON HODOSCOPE URAGAN
USING NEURAL NETWORKS OF DEEP LEARNING**

В.Г. Гетманов

*Геофизический центр РАН,
Москва, Россия, v.getmanov@gcras.ru
Институт физики Земли РАН им. О.Ю. Шмидта,
Москва, Россия*

А.Д. Гвишиани

*Геофизический центр РАН,
Москва, Россия, a.gvishiani@gcras.ru
Институт физики Земли РАН им. О.Ю. Шмидта,
Москва, Россия*

А.А. Соловьев

*Геофизический центр РАН,
Москва, Россия, a.soloviev@gcras.ru
Институт физики Земли РАН им. О.Ю. Шмидта,
Москва, Россия*

К.С. Зайцев

*Национальный исследовательский ядерный университет
МИФИ,
Москва, Россия, kszajtsev@mephi.ru*

М.Е. Дунаев

*Национальный исследовательский ядерный университет
МИФИ,
Москва, Россия, mxd.dunaev@mail.ru*

Э.В. Ехлаков

*Национальный исследовательский ядерный университет
МИФИ,
Москва, Россия, fruha1980@gmail.com*

V.G. Getmanov

*Geophysical Center RAS,
Moscow, Russia, v.getmanov@gcras.ru
Schmidt Institute of Physics of the Earth RAS,
Moscow, Russia*

A.D. Gvishiani

*Geophysical Center RAS,
Moscow, Russia, a.gvishiani@gcras.ru
Schmidt Institute of Physics of the Earth RAS,
Moscow, Russia*

A.A. Soloviev

*Geophysical Center RAS,
Moscow, Russia, a.soloviev@gcras.ru
Schmidt Institute of Physics of the Earth RAS,
Moscow, Russia*

K.S. Zajtsev

*National Research Nuclear University MEPHI,
Moscow, Russia,
kszajtsev@mephi.ru*

M.E. Dunaev

*National Research Nuclear University MEPHI,
Moscow, Russia,
dunaev@mail.ru*

E.V. Ehlakov

*National Research Nuclear University MEPHI,
Moscow, Russia,
fruha1980@gmail.com*

Аннотация. Решена задача распознавания геомагнитных бурь на основе матричных временных рядов наблюдений мюонного годоскопа УРАГАН с использованием нейронных сетей глубокого обучения. Проведен выбор варианта программного модуля нейронной сети, определены его параметры. Распознавание геомагнитных бурь рассмотрено с применением процедур бинарной классификации, сформировано правило принятия решений. Предложены оценки вероятностей правильных и ложных распознаваний. Экспериментально исследовано распознавание геомагнитных бурь; для назначенного Dst -порога $Y_{D0} = -45$ нТл получены приемлемые вероятности правильных и ложных распознаваний $\beta = 0.8212$ и $\alpha = 0.0047$. Подтверждены эффективность и перспективность предложенного нейросетевого подхода.

Ключевые слова: геомагнитные бури, распознавание, нейронные сети, вероятности правильных и ложных распознаваний, матричные наблюдения, мюонный годоскоп.

Abstract. We solve the problem of recognizing geomagnetic storms from matrix time series of observations with the URAGAN muon hodoscope, using deep learning neural networks. A variant of the neural network software module is selected and its parameters are determined. Geomagnetic storms are recognized using binary classification procedures; a decision-making rule is formed. We estimate probabilities of correct and false recognitions. The recognition of geomagnetic storms is experimentally studied; for the assigned Dst threshold $Y_{D0} = -45$ nT we obtain acceptable probabilities of correct and false recognitions, which amount to $\beta = 0.8212$ and $\alpha = 0.0047$. We confirm the effectiveness and prospects of the proposed neural network approach.

Keywords: geomagnetic storms, recognition, neural networks, probabilities of correct and false recognitions, matrix observations, muon hodoscope.

ВВЕДЕНИЕ

В статье рассматривается распознавание геомагнитных бурь (ГМБ) на основе цифровой обработки матричных временных рядов наблюдений (data set) мюонного годоскопа (МГ) УРАГАН с применением нейронных сетей (НС) глубокого обучения (deep learning). В рамках данной статьи распознавание интерпретируется как задача, состоящая в принятии решений о наличии или отсутствии ГМБ для заданного момента времени с применением МГ-наблюдений.

Распознавание ГМБ на основе нейросетевой цифровой обработки матричных временных рядов МГ-наблюдений представляет собой актуальную научную проблему в солнечно-земной физике.

Геомагнитные возмущения возникают вследствие воздействия на магнитосферу Земли плазменных образований от солнечных корональных выбросов масс. ГМБ представляют собой геомагнитные возмущения, амплитуды которых в среднем больше заданной.

Как известно, активность магнитного поля Земли характеризуется геомагнитными индексами. Одним из наиболее распространенных является почасовая Dst -индекс, введенный и описанный в [Suigiura, 1964]. Он определяется на основе значений составляющих вектора напряженности геомагнитного поля четырех экваториальных магнитных обсерваторий, разнесенных по долготе, и вычисляется усреднением с часовой дискретностью. Dst -индексы измеряются в нанотеслах: для спокойных состояний магнитосферы $Dst = +20 \div -40$ нТл; для ГМБ — $-50 \div -150$ нТл; в исключительных случаях они выходят за указанный диапазон. Временной ряд Dst -индексов взят с сайта WDCG (World Data Center of Geomagnetism, Kyoto) [<https://wdc.kugi.kyoto-u.ac.jp>].

Для решений задач солнечно-земной физики достаточно часто применяются нейронные сети [Бархатов, 2010; Бернгардт, 2022]. Целый ряд публикаций рассматриваемой предметной области, связанных с НС, отличается информационными источниками, нейросетевыми структурами, вариантами задачи и возможностями получения решений без построения физических моделей, что может быть с успехом использовано для исследования сложных геофизических систем.

Работы [Pallochia et al., 2006; Lundstredt, 1997] посвящены нейросетевому анализу ГМБ, основанному на данных по солнечному ветру и использованию многослойных перцептронов. В [Gruet et al., 2018] представлен метод, сочетающий рекуррентную НС с кратковременной памятью и моделью гауссовского процесса для оценивания характеристик Dst -индексов. В [Stepanova, Perez, 2000] с помощью многослойного перцептрона исследуются вариации Dst на несколько часов вперед. В [Ефиторов и др., 2018; Dolenko et al., 2005; Myagkova et al., 2021] рассматриваются возможности использования временных рядов геомагнитных Dst -индексов и их связей с параметрами, а также методы машинного обучения НС с использованием классических перцептронов и рекуррентных сетей.

В работах [Белов и др., 2022; Getmanov et al., 2022] описан подход, состоящий в использовании скалярных временных рядов МГ-наблюдений и сверточных НС для анализа ГМБ. Реализация предложенного здесь подхода к распознаванию ГМБ на основе матричных временных рядов МГ-наблюдений и НС глубокого обучения имеет целью продемонстрировать его работоспособность и возможную перспективу использования.

1. НАБЛЮДЕНИЯ МЮОННОГО ГОДОСКОПА УРАГАН И ВАРИАНТЫ РЕШЕНИЙ ЗАДАЧИ РАСПОЗНАВАНИЯ ГМБ НА ОСНОВЕ НС-ТЕХНОЛОГИЙ

В данной статье распознавание ГМБ основано на наблюдениях мюонного годоскопа УРАГАН [Yashin et al., 2015], сконструированного в НИЯУ МИФИ. Мюоны являются элементарными частицами, образующимися в результате ядерных реакций между релятивистскими космическими протонами и отдельными ядрами атомов, которые входят в состав верхних слоев земной атмосферы [Мурзин, 2007; Астапов и др., 2014]. МГ УРАГАН является компьютеризованным измерительным устройством, определяющим величины ПМ (поток мюонов) путем подсчета числа мюонов, падающих на апертуру МГ для заданной системы телесных углов и установленного шага дискретности по времени. В меняющихся во времени оценках величин ПМ, полученных из МГ-наблюдений, содержится информация об экстремальных гелиосферных событиях и возможных предстоящих ГМБ.

Результаты подсчета числа мюонов с помощью МГ формируются в матричный временной ряд первичных исходных МГ-наблюдений $X(i, j, T_{\text{rg}}, T_k)$, состоящих из пуассоновских чисел $i=1, \dots, N_1, j=1, \dots, N_2, N_1=90, N_2=76; T$ — установленный шаг дискретности по времени; k — временной индекс; обычно $T=1/60$ ч (1 мин); $T_{\text{rg}}=58.5$ с — длительность интервалов регистрации (подсчета числа) мюонов.

Азимутальные и зенитные индексы i, j определяют систему телесных углов $\varphi_i = \Delta\varphi(i, 1), \vartheta_j = \Delta\vartheta(j-1), \Delta\varphi=1^\circ, \Delta\vartheta=4^\circ, i=1, \dots, N_1, j=1, \dots, N_2$, в которых проводится оценка ПМ. В (i, j) -е ячейки для МГ-матриц дискретно по времени помещаются количества собранных мюонов, соответствующих телесным углам φ_i, ϑ_j .

Первичные минутные нормированные матричные МГ-наблюдения $X(i, j, T_k)$ формируются на основе исходных МГ-наблюдений и определяют количества зарегистрированных частиц для индексов i, j , приведенных к 1 с,

$$X(i, j, T_k) = X(i, j, T_{\text{rg}}, T_k) / T_{\text{rg}}, k = 1, 2, \dots \quad (1)$$

Временной ряд вторичных часовых нормированных матричных МГ-наблюдений образуется из минутных наблюдений (1) путем их усреднения на 60-мин интервале времени $T_0=60T$.

$$X(i, j, T_0n) = \sum_{k=k_1(n)}^{k_2(n)} X(i, j, T_k) / 60, \quad (2)$$

$$k_1(n) = 1 + 60(n-1), \quad k_2(n) = 60n, \quad n = 1, 2, \dots$$

Рассматривались модуляционные и шумовые возмущения в матричных временных рядах часовых нормированных МГ-наблюдений $X(i, j, T_0n)$ (2), взятых из Data Base of Muon Hodoscope МЕРФИ [<http://www.nevod.mephi.ru/>]. Формировался матричный временной ряд из МГ-наблюдений с начальным индексом $n=1$, соответствующим моменту времени 01.01.2013, 00:00 UT.

На рис. 1 показан пример 2D-изображения матрицы часовых нормированных МГ-наблюдений $X(i, j, T_0n_0)$, $i=1, \dots, N_1, j=1, \dots, N_2$, полученного из указанного временного ряда для индекса $n_0=50300$. Видно, что двумерная функция $X(i, j, T_0n)$ содержит значительные модуляции и шумы. Элементы матрицы для зенитных углов с индексами $j \approx 25 \div 30$ принимают максимальные значения; для зенитных углов с $j \approx 1 \div 2, 75 \div 76$ — минимальные значения, при этом они различаются в десятки раз. Азимутальные модуляции для $X(i, j, T_0n_0)$ существенно меньше зенитных модуляций.

На рис. 2 показан график одномерной функции средних величин часовых МГ-наблюдений $S(T_0n)$, вычисленной на временном месячном участке с индексами $n_1=50100, n_2=50800$ по формуле

$$S(T_0n) = \frac{1}{N_1 N_2} \sum_{i=1}^{N_1} \sum_{j=1}^{N_2} X(i, j, T_0n), \quad n_1 \leq n \leq n_2. \quad (3)$$

Видны ~30 периодов зашумленных суточных колебаний функции $S(T_0n)$. Из каталога ГМБ [<https://www.izmiran.ru/ionosphere/weather/storm/>] можно найти информацию, что на рассматриваемом месячном временном участке имела место достаточно сложная геомагнитная обстановка — произошли три *Dst*-бури. Из рисунка видно, что МГ-наблюдения определенным образом реагируют на изменения ГМБ; необходимо заметить, что минимальные и максимальные величины $S(T_0n)$ различались всего на ~1.9 %. Можно заключить, что распознавание модуляций от ГМБ в модулированных и зашумленных матричных временных рядах МГ-наблюдений с помощью традиционных время-частотных технологий является в значительной степени проблематичным.

Допускаются два варианта решений задачи распознавания ГМБ, которые основываются на временных рядах матричных МГ-наблюдений и НС-технологиях. Первый базируется на формировании из матричных МГ-наблюдений временных рядов скалярной функции $S(T_0n)$ из (3). Такой вариант [Белов и др., 2022; Getmanov et al., 2022] позволяет снизить требования к ЭВМ при реализации НС, однако за счет снижения эффективности распознавания ГМБ. Второй вариант базируется на прямом использовании матричных временных рядов МГ-наблюдений, требующем для НС использования ЭВМ с высокой производительностью, позволяющей повысить эффективность распознавания ГМБ. В данном случае за основу взят второй вариант решения.

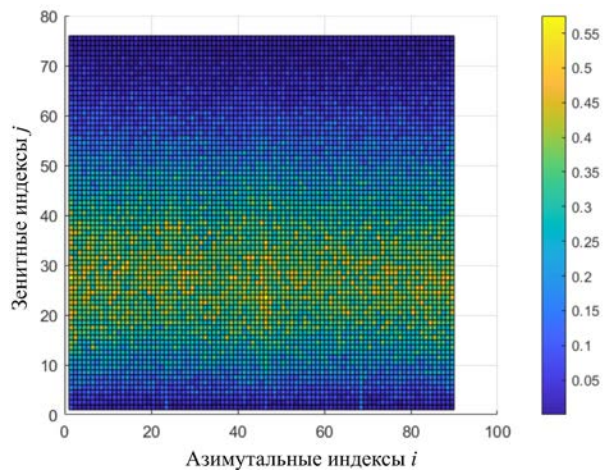


Рис. 1. Пример 2D-изображения матрицы часовых нормированных МГ-наблюдений $X(i, j, T_0n_0)$




Рис. 2. График одномерной функции средней величины часовых МГ-наблюдений $S(T_0n)$

Необходимо отметить, что в публикациях [Chinkin et al., 2019, Getmanov et al., 2022] были рассмотрены задачи обнаружения так называемых локальных анизотропий для ПМ, послужившие методической основой данной статьи.

2. АЛГОРИТМ ВЫЧИСЛИТЕЛЬНЫХ ОПЕРАЦИЙ РЕШЕНИЯ ЗАДАЧИ РАСПОЗНАВАНИЯ ГМБ, НЕЙРОННАЯ СЕТЬ ResNet34

Алгоритм решения задачи распознавания ГМБ основывается на предположении, что между МГ-наблюдениями и *Dst*-индексами существует зависимость сложного вида, искаженная помехами. В статье реализуется построение модели указанной зависимости *Dst*-индексов от МГ-наблюдений с помощью НС глубокого обучения.

Используется матричный временной ряд МГ-наблюдений $X(i, j, T_0n) = X_M(n)$ и временной ряд скалярных *Dst*-индексов $Y_D(n)$, которые сформированы в единой международной шкале времени UTC. Дискретизация была осуществлена для моментов времени T_0n .

МГ-наблюдения $X_M(n)$ и *Dst*-индексы $Y_D(n)$ определяются на девятилетнем временном участке. На этапе обучения с индексами $1 \leq n \leq n_{f0}, n_{f0} = 62128$ используются МГ-наблюдения и *Dst*-индексы; результа-

том этого этапа является построенная НС-модель. На этапе тестирования используются МГ-наблюдения с индексами $n_{f0}+1 \leq n \leq n_{f1}$, $n_{f1}=70128$; на этом этапе реализуется контроль этапа обучения построенной НС-модели. На этапе валидации используются МГ-наблюдения для индексов $n_{f1}+1 \leq n \leq n_f$, $n_f=78888$; вычисляются модельные оценки Dst -индексов $Y_D^\circ(n)$ с помощью НС-модели и на основе только датасета $X_M(n)$, Dst -индексы применяются только для оценивания вероятностей распознавания ГМБ.

Алгоритм задачи распознавания ГМБ включает четыре этапа.

На этапе 1 производится предварительная цифровая обработка для исходного матричного временного ряда МГ-наблюдений $X_M(n)$ и временного ряда Dst -индексов $Y_D(n)$, осуществляется их фильтрация с целью устранения низкочастотных и высокочастотных шумов и масштабирование для обеспечения соизмеримости переменных, необходимые для эффективного обучения НС. Результаты предварительной обработки обозначаются, как X_{M1} , X_{M2} , Y_{D1} .

На этапе 2 реализуется обучение и тестирование НС. Используется матричный временной ряд X_{M1} и обучающий скалярный временной ряд Y_{D1} , $1 \leq n \leq n_{f1}$. Формируется НС-модель и проводится определение ее качества.

На этапе 3 этапа валидации реализуется построение оценок Dst -индексов Y_D° . Здесь используются переменные X_{M2} на интервале $n_{f1}+1 \leq n \leq n_f$ и НС-модель, полученная на предыдущем этапе.

На этапе 4 реализуется процедура принятия решений для распознаваний ГМБ путем сравнения вычисленных модельных оценок Dst -индексов $Y_D^\circ(n)$ с назначаемым порогом Y_{D0} .

На рис. 3 помещена укрупненная схема нейросетевого алгоритма вычислительных операций с обозначенными выше переменными, поясняющая решение задачи распознавания ГМБ.

Результаты решения сформулированной задачи распознавания ГМБ, связанные с цифровой обработкой большого объема данных, были получены на основе применения облачных технологий. Использовался суперкомпьютерный вычислительный центр НИЯУ МИФИ для выполнения ресурсоемких вычислительных работ [<https://it.mephi.ru/hpc/performance>], которые требовались для НС глубокого обучения.

Было произведено формирование варианта структуры НС глубокого обучения на основе языка программирования Python и библиотеки модулей PyTorch. Рассматривались варианты модулей: Efficientnet [<https://arxiv.org/abs/1905.11946/>], VGG [<https://arxiv.org/abs/1409.1556v6>], DenseNet [<https://arxiv.org/abs/1608.06993v5>], Inception-v3 и ResNet [<https://arxiv.org/abs/1512.00567v3>] из данной библиотеки. Для реализации были взяты модуль сети ResNet и его модификация ResNet34. Для этого модуля характерна высокая точность и малое количество тренируемых параметров по сравнению с другими упомянутыми модулями. Модификация ResNet34 была выбрана вследствие того, что в исследованиях обучений указанных нейросетей этот модуль

заял второе место, работая без аугментации [<https://arxiv.org/pdf/2107.07699.pdf>]. Общий вид структуры НС ResNet34 содержится в [<https://arxiv.org/abs/1512.03385>].

Размерность пакета входных матриц Δn назначалась на основе анализа результатов предварительных вычислительных экспериментов с НС ResNet34 и располагаемых МГ-наблюдений. На выходе НС вырабатывались модельные оценки Dst -индексов Y_D° , которые далее использовались для задачи распознавания ГМБ.

3. ОБУЧЕНИЕ, ТЕСТИРОВАНИЕ, ВАЛИДАЦИЯ И МЕТРИКИ КАЧЕСТВА

Обучение выбранной НС осуществлялось для вычисления оптимальных весовых коэффициентов НС-модели. Использовался поисковый алгоритм градиентного спуска Adam, принимались значения параметров алгоритма $\alpha_E=0.001$, $\beta_1=0.9$, $\beta_2=0.999$, по умолчанию принималось значение $\epsilon=10^{-8}$, взятое из [<https://arxiv.org/pdf/1412.6980.pdf>]. Параметр α_E — показатель скорости обучения, β_1 — показатель экспоненциального затухания для оценок первого момента, β_2 — показатель экспоненциального затухания для оценок второго момента, ϵ — параметр, добавляемый к знаменателю для улучшения числовой стабильности, который использовался для управления процедурой градиентного спуска [<https://pytorch.org/docs/stable/generated/torch.optim.Adam.html>; Ba, Kingma, 2015].

Количество свободных параметров реализованной модели обучения составило 21.5 миллионов — это количество было подсчитано с помощью кода, а именно, суммировались количества обучаемых параметров каждого блока модели. Объем датасета обучения составил величину $N_1 \times N_2$ × общее количество часов в датасете — очевидно, объем данного датасета для обучения существенно превышал указанное количество параметров.

Тестирование проводилось для определения качества НС-модели, построенной на этапе обучения. Этот этап выполнялся на датасете тестирования, отличном от датасета обучения и валидации.

Валидация построенной НС-модели проводилась на основе вычисления модельных оценок Dst -индексов Y_D° . Из них образовывался временной ряд и к его элементам были применены процедуры бинарной классификации для распознавания ГМБ [<https://www.larndata.com/glossary/binary-classification/>]. Проводились сравнения значений $Y_D^\circ(n)$ с назначаемым порогом распознавания Y_{D0} .

По условиям задачи на участке валидации исходные Dst -индексы использовались только для численного оценивания вероятностей распознавания ГМБ. В силу сделанного замечания с помощью неравенств

$$Y_D(n) \leq Y_{D0}, \quad n_{f1} + \Delta n + 1 \leq n \leq n_f \quad (4)$$

подсчитывалось число индексов с ГМБ-событиями $N_{1,ГМБ}$ и число индексов без ГМБ-событий $N_{0,ГМБ}$.

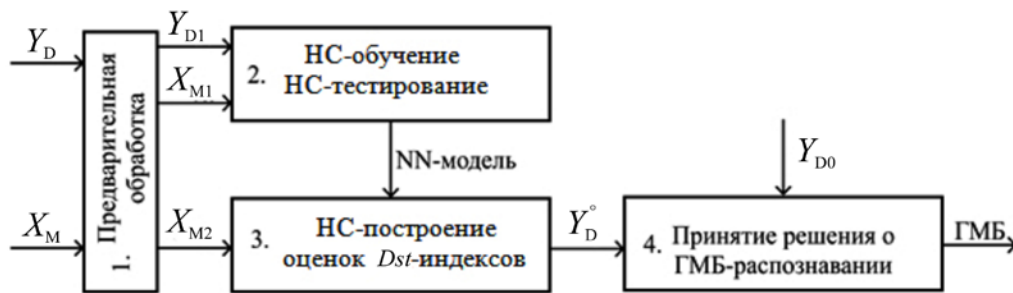


Рис. 3. Схема алгоритма вычислительных операций решения задачи распознавания ГМБ

Вычислялись количество правильных распознаваний ГМБ $N_{R, ГМБ}$ и количество ложных $N_{F, ГМБ}$ с учетом того, что в данном случае для каждого индекса n заранее было известно, имелось или не имелось для него ГМБ-событие.

Вводились вероятности β правильных и α ложных распознаваний ГМБ в виде следующих очевидных формул

$$\beta = N_{R, ГМБ} / N_{1, ГМБ}, \quad \alpha = N_{F, ГМБ} / N_{0, ГМБ}.$$

Функция ошибки. Оптимизация параметров НС-модели выполнялась по значениям функции ошибки. Как правило, для задач регрессии в качестве таковой принималась функция, обозначаемая как *RMSE* [Chen et al., 2022] и представляющая собой среднеквадратичное значение ошибки — разности между модельными оценками $Y_D^o(n)$ и фактически значениями переменных $Y_D(n)$.

$$RMSE = \left(1 / (n_f - n_{f1} - \Delta n) \right) \times \sum_{n=n_{f1}-\Delta n}^{n_f} (Y_D^o(n) - Y_D(n))^2.$$

Вычислительные эксперименты показали, что использованный здесь оптимизационный градиентный метод первого порядка Adam для данной функции потерь удовлетворительно работал на практике и выгодно отличался от других методов стохастической оптимизации. Этот метод прост в реализации, эффективен в вычислительном отношении, хорошо подходит для задач с большими объемами данных со сходимостью, которая сопоставима с наиболее известными результатами в рамках процедур выпуклой оптимизации.

Останов обучения проводился на основе визуального анализа значений функции ошибки, когда график значений *RMSE* переходил на плато; при этом тестирование реализовывало контроль отсутствия переобучения.

Метрики качества. Определялась метрика качества распознавания по аналогии с метрикой Recall из [https://en.wikipedia.org/wiki/Binary_classification]. С учетом постановки решаемой задачи метрика качества принималась в виде

$$G0(\alpha, \beta) = \beta + 1 - \alpha, \tag{5}$$

содержание которой совершенно прозрачно с физической точки зрения. Из последнего выражения сле-

довало, что при возрастании вероятности β и уменьшении вероятности α возрастала метрика качества $G0(\alpha, \beta)$.

Метрика качества бинарной классификации $G0$ обычно используется для так называемых сбалансированных данных, распределенных равномерно. В случае возможного дисбаланса данных эта метрика сильно искажает реальное качество классификации. Решение предлагаемой задачи для сравнения целесообразно рассматривать на основе метрики $G1$, слабо чувствительной к дисбалансу данных. На основе [https://helenkapatsa.ru/otsienka_f1] $G1(\alpha, \beta)$ записывается в виде

$$G1(\alpha, \beta) = 2A(\alpha, \beta)R(\alpha, \beta) / (A(\alpha, \beta) + R(\alpha, \beta)), \tag{6}$$

где

$$\begin{aligned} A(\alpha, \beta) &= TP / (TP + FP), \\ R(\alpha, \beta) &= TP / (TP + FN), \\ TP &= \beta, NP = 1 - \alpha, FP = 1 - \beta, FN = \alpha. \end{aligned}$$

4. ОСТАНОВ ОБУЧЕНИЯ НА ОСНОВЕ МЕТРИКИ *RMSE*, ОЦЕНИВАНИЕ ВЕРОЯТНОСТЕЙ ПРАВИЛЬНОГО И ЛОЖНОГО РАСПОЗНАВАНИЯ ГМБ, ВЫЧИСЛЕНИЕ МЕТРИК КАЧЕСТВА $G0, G1$

Останов этапа обучения проводился на основе вычислений функции ошибки, полученных в результате обучения НС. Обозначались значения функций ошибки для тренировочной и валидационной выборок соответственно в виде $RMSE1(N_E)$ и $RMSE2(N_E)$, где N_E — количество эпох. Реализовывался визуальный анализ вычисленных оценок.

На рис. 4 показаны функция оценки $RMSE1(N_E)$, вычисленная для датасета этапа обучения, и функция оценки $RMSE2(N_E)$ для датасета этапа валидации.

Визуальный анализ графиков позволил
1) принять решение об оптимальном количестве эпох для этапа обучения $N_E^o = 20$, для этапа валидации $N_E^v = 30$;

2) сделать заключение об отсутствии переобучения НС-модели.

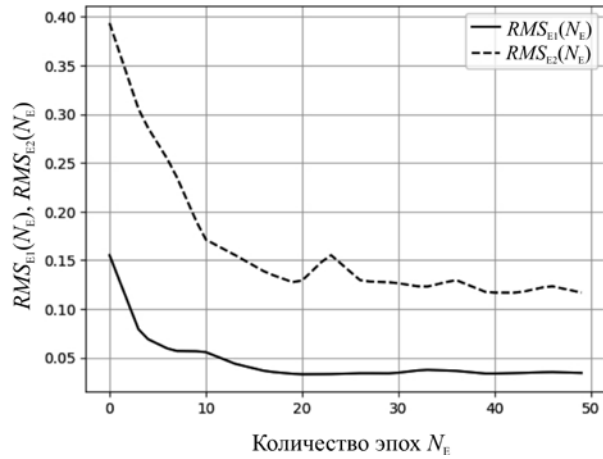


Рис. 4. Оценки $RMSE1(N_E)$ и $RMSE2(N_E)$ для этапов обучения и валидации

Оценивались вероятности правильного и ложного распознаваний ГМБ. Фиксировался порог Y_{D0} и рассматривался момент времени с индексом n , для которого имела место ГМБ при выполнении сравнений $Y_D(n) \leq Y_{D0}$ из (4). Количество $N_{1,ГМБ}$ состояний с ГМБ определялось путем подсчета выполнений данного неравенства на временном участке контроля для индексов $n_{f1} + \Delta n + 1 \leq n \leq n_f$, где Δn — размерность пакета входных матриц.

Проводилась операция суммирования

$$N_{1,ГМБ} = \sum_{n=n_{f1}+\Delta n+1}^{n_f} H(Y_{D0} - Y_D(n)), \quad (7)$$

где $H(x)$ — функция Хевисайда $H(x)=1, x \geq 0, H(x)=0, x < 0$. Количество $N_{0,ГМБ}$ состояний без ГМБ на интервале $n_{f1} + \Delta n + 1 \leq n \leq n_f$ находилось на основе выражения $N_{0,ГМБ} = n_f - n_{f1} - \Delta n - 1 - N_{1,ГМБ}$.

Определялись $N_{R,ГМБ}$ — количество правильных распознаваний ГМБ с помощью оценок Dst -индексов $Y_D^\circ(n)$ и β — оценка вероятности правильного распознавания ГМБ с помощью суммирования и вычисления отношения

$$N_{R,ГМБ} = \sum_{n=n_{f1}+\Delta n+1}^{n_f} H(Y_{D0} - Y_D(n))H(Y_{D0} - Y_D^\circ(n)), \quad (8)$$

$$\beta = \frac{N_{R,ГМБ}}{N_{1,ГМБ}}.$$

Находились $N_{F,ГМБ}$ — количество ложных распознаваний ГМБ и α — оценка вероятности ложного распознавания ГМБ по аналогии с (8)

$$N_{F,ГМБ} = \sum_{n=n_{f1}+\Delta n+1}^{n_f} H(Y_D(n) - Y_{D0})H(Y_{D0} - Y_D^\circ(n)), \quad (9)$$

$$\alpha = \frac{N_{F,ГМБ}}{N_{0,ГМБ}}.$$

Вычислялись метрики качества $G0, G1$ (5), (6) на контрольном временном участке с индексами $n_{f1} + \Delta n + 1 \leq n \leq n_f$ на основе датасета $X_M(n)$. С этой целью проводилась оценка модельных Dst -индексов $Y_D^\circ(n)$, которые сравнивались с порогом Y_{D0} .

В соответствии с п. 3 назначалась величина размерности пакета входных матриц $\Delta n=60$, которая оставлялась таковой для расчетов во всей статье. Вычислялись дискретные значения порога распознавания $Y_{D0}(l) = \bar{Y}_{D1} + \Delta Y_{D0}(L-1)$, $\bar{Y}_{D1} = -70$ нТл, $\Delta Y_{D0} = 5$ нТл, $l=1, 2, \dots, 9$. Определялись оценки $\beta(Y_{D0}(l))$ и $\alpha(Y_{D0}(l))$ вероятностей правильного и ложного распознавания ГМБ по формулам (7)–(9) в зависимости от параметров $Y_{D0}(l)$.

На рис. 5, а, б показаны результаты расчетов оценок вероятностей $\beta(Y_{D0})$ и $\alpha(Y_{D0})$ в зависимости от Y_{D0} . Очевидно, что оценки вероятностей возрастали с увеличением порога. Расчеты позволили сделать вывод, что для диапазона $-70 \leq Y_{D0} \leq -50$ нТл среднее значение вероятности ложного распознавания ГМБ составило $\alpha \approx 0.001$, при этом вероятность правильного распознавания принимала значение $0.575 \leq \beta \leq 0.75$; для порога $Y_{D0} = -37.5$ нТл выполнялись соотношения $\alpha \approx 0.02$ и $\beta \approx 0.875$; для порога $Y_{D0} = -34.0$ нТл имели место $\alpha \approx 0.045$, $\beta \approx 0.91$.

На основе оценок $\beta(Y_{D0}), \alpha(Y_{D0})$ сделаны вычисления оценок метрик (5), (6) $G0$ и $G1$ в зависимости от Y_{D0} . Построены их графики и проведено сравнение метрик.

Рассмотрение оценок метрик на рис. 6, а, б позволило сделать следующие выводы: 1) метрики $G0$ и $G1$ оказались близки по значениям, различаясь примерно на константу при сравнении характера их зависимости от порога распознавания Y_{D0} ; возможное предположение, что исходные МГ-наблюдения были несбалансированны, оказалось недостаточно точным и противоречило расчетам метрик; 2) анализ положений максимумов на графиках метрик дал возможность установить оптимальное значение порога распознавания (с позиции метрик $G0$ и $G1$), которое составило $Y_{D0}^\circ \approx -35$ нТл.

5. ВЫЧИСЛЕНИЕ ОЦЕНОК МОДЕЛЬНЫХ Dst -ИНДЕКСОВ И РЕЗУЛЬТАТОВ РАСПОЗНАВАНИЯ ГМБ

Был выбран шестимесячный временной участок 2021.07.01–2022.01.01, расположенный в границах участка контроля. На рис. 7 показаны реальные $Y_D = Y_D(T_0 n)$ и модельные $Y_{D0}^\circ = Y_{D0}^\circ(T_0 n)$ Dst -индексы. Для назначенного в данном случае порога $Y_{D0} = -45$ нТл на рассмотренном временном участке наблюдались четыре ГМБ (отмечены крестом в кружке).

Рассмотрение графика $Y_{D0}^\circ(T_0 n)$ с учетом установленного порога Y_{D0} показало, что наблюдались три правильных ГМБ-распознавания, одно ложное (отмечено минусом в кружке) и один пропуск правильного ГМБ-распознавания. С использованием (7)–(9) были вычислены оценки вероятностей правильных и ложных распознаваний ГМБ.

Результаты вычислений по разработанному алгоритму для шестимесячного временного участка с уче-




Рис. 5. Результаты оценок правильного $\beta(Y_{D0})$ (а) и ложного $\alpha(Y_{D0})$ (б) распознавания ГМБ




Рис. 6. Метрики $G0$ (а) и $G1$ (б) в зависимости от порога распознавания Y_{D0}

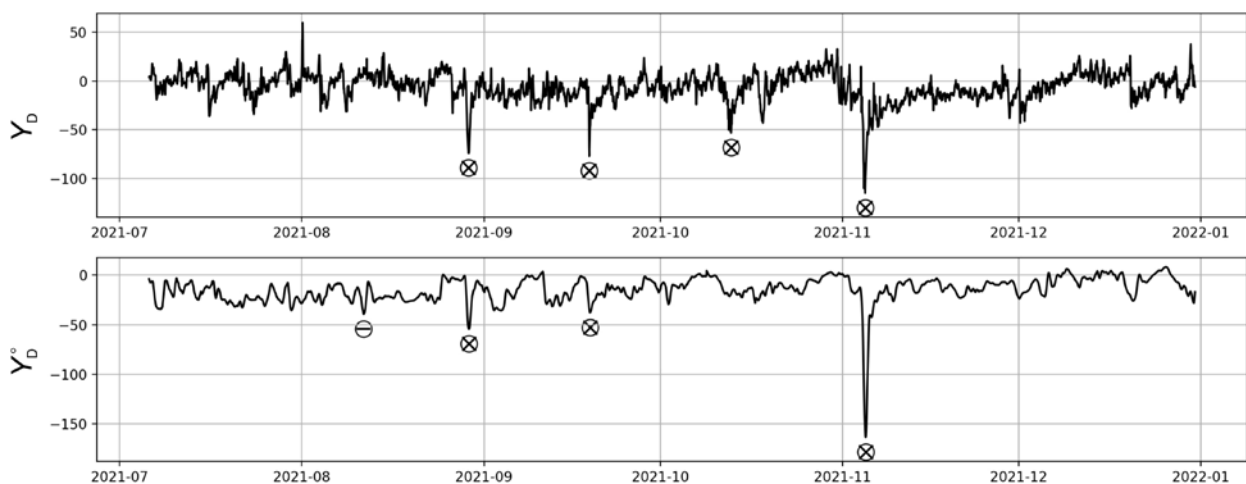


Рис. 7. Реальные $Y_D(T_0n)$ и модельные $Y_{D0}^{\circ}(T_0n)$ Dst-индексы

том назначенного порога $Y_{D0} = -45$ нТл и результатов расчетов с использованием рис. 6, а, б позволили удостовериться в получении приемлемых оценок вероятностей правильных и ложных распознаваний, которые составили $\beta \approx 0.8212$ и $\alpha \approx 0.0047$.

Анализ алгоритма вычисления вероятностей правильных и ложных распознаваний ГМБ и экспе-

риментальное исследование результатов распознавания ГМБ позволили заключить, что предложенный нейросетевой подход оказался в значительной степени эффективным и перспективным для задач солнечно-земной физики.

Предложенное в данной статье построение НС, основанное на использовании матричных времен-

ных рядов МГ-наблюдений, превышает по эффективности подход, описанный в [Белов и др., 2022; Гетманов и др., 2022] и базирующийся на формировании из матричных МГ-наблюдений скалярных временных рядов значений функций (3).

ЗАКЛЮЧЕНИЕ

1. Разработанный в статье метод распознавания ГМБ на основе анализа и обработки временных рядов матричных наблюдений мюонного годоскопа УРАГАН с помощью НС глубокого обучения оказался работоспособным и эффективным.

2. В результате проведенных исследований и вычислительных экспериментов были выбраны архитектура НС ResNet34 и размерность пакета входных матриц $\Delta l^\circ = 60$, наиболее подходящих для рассматриваемой задачи.

3. На основе экспериментальных исследований предложенных алгоритмов распознавания ГМБ на контрольном датасете получены оценки вероятностей, которые характеризуют качество распознавания ГМБ.

3.1. Результаты расчетов вероятностей распознавания ГМБ на участке контроля позволили сделать вывод, что для порога $Y_{D0} = -45$ нТл при выполнении условия-ограничения для вероятности ложного распознавания $\alpha = 0.02$ вероятность правильного распознавания принимала значение $\beta = 0.875$.

3.2. Цифровая обработка МГ-наблюдений для шестимесячного участка контроля позволила получить оценки вероятностей правильного $\beta = 0.8212$ и ложного $\alpha = 0.0047$ распознавания ГМБ.

3.3. Анализ распознаваний ГМБ с использованием метрик качества $G0$, $G1$ позволил установить сбалансированность используемых МГ-наблюдений и назначить подходящий порог распознавания $Y_{D0}^\circ = -35$ нТл.

4. Проведенное экспериментальное исследование позволило установить, что предложенный в статье подход к построению НС глубокого обучения, основанный на использовании временных рядов, состоящих из матриц МГ-наблюдений, превысил по эффективности подход, описанный в [Белов и др., 2022; Гетманов и др., 2022], который базировался на формировании из матричных МГ-наблюдений скалярных временных рядов усредненных величин часовых МГ-наблюдений.

5. Разработанный метод распознавания показал перспективность и может быть применен во многих научных и технических приложениях, например в случае возможного внезапного отсутствия (пропуска) Dst -индексов WDCG распознавание ГМБ может быть осуществлено на основе предварительно построенных моделей Dst -индексов, работающих только на основе МГ-наблюдений, а также при необходимости краткосрочного прогнозирования ГМБ, которое возможно реализовать на основе экстраполяции для МГ-наблюдений.

Работа выполнена в рамках утвержденных Минобрнауки России государственных заданий Геофи-

зического центра РАН и Института физики Земли им. О.Ю. Шмидта РАН.

Авторы статьи выражают благодарность руководству НОЦ «НЕВОД» НИЯУ МИФИ за предоставленные для расчетов наблюдения мюонного годоскопа УРАГАН.

СПИСОК ЛИТЕРАТУРЫ

Астапов И.И., Барбашина Н.С., Борог В.В. и др. Мюонная диагностика магнитосферы и атмосферы Земли. М.: МИФИ, 2014. 132 с.

Бархатов Н.А. Искусственные нейронные сети в задачах солнечно-земной физики. Нижний Новгород: Поволжье, 2010. 707 с.

Белов А.В., Гвишиани А.Д., Гетманов В.Г. и др. Распознавание геомагнитных бурь на основе нейросетевых модельных оценок Dst -индексов. *Известия РАН. Теория и системы управления*. 2022. № 1. С. 56–66.

Бернгардт О.Н. Первый сравнительный анализ метеорного эха и спорадического рассеяния, идентифицированных самообучившейся нейронной сетью по данным радаров ЕКВ и MAGW ИСЗФ СО РАН. *Солнечно-земная физика*. 2022. Т. 8, № 4. С. 66–76.

Гетманов В.Г., Чинкин В.Е., Гвишиани А.Д. и др. Прогнозирование геомагнитных бурь на основе нейросетевой цифровой обработки совместных наблюдений мюонного годоскопа УРАГАН и станций нейтронных мониторов. *Геомагнетизм и аэронавигация*. 2022. Т. 62, № 4. С. 470–481.

Ефиторов А.О., Мягкова И.Н., Широкий В.Р. и др. Прогнозирование Dst -индекса, основанное на методах машинного обучения. *Космические исследования*. 2018. Т. 56, № 6. С. 420–428.

Мурзин В.С. Астрофизика космических лучей. М.: Университетская книга. 2007. 488 с.

Ba J.L., Kingma D.P. Adam: A method for stochastic optimization. 3rd International Conference on Learning Representations, ICLR 2015 — Conference Track Proc. 2015. P. 1–15.

Chen X., Yu R., Ullah S., et al. A novel loss function of deep learning in wind speed forecasting. *Energy*. 2022. Vol. 238. P. 121808.

Chinkin V.E., Astapov I.I., Gvishiani A.D., et al. Method for the identification of heliospheric anomalies based on the functions of the characteristic deviations for the observation matrices of the muon hodoscope. *Physics of Atomic Nuclei*. 2019, vol. 82, no. 6, pp. 924–928.

Dolenko S.A., Orlov Yu.V., Persianinov I.G., Shugai Ju.S. Neural network algorithm for events forecasting and its application to space physics data. *Lecture Notes in Computer Science*. 2005. Vol. 3697. P. 527–532.

Getmanov V.G., Chinkin V.E., Gvishiani A.D., et al. Application of indicator matrices for the recognition of local anisotropies of muon fluxes in time series of matrix observations of the URAGAN hodoscope. *Pattern Recognition and Image Analysis: Adv. in Mathematical Theory and Applications*. 2022. Vol. 32, no. 3. P. 717–728.

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*. 2018. Vol. 16, iss. 11. P. 1882–1896. DOI: [10.1029/2018SW001898](https://doi.org/10.1029/2018SW001898).

Lundstedt H. Geomagnetic storm predictions from solar wind data with the use of dynamic neural networks. *J. Geophys. Res.* 1997. Vol. 102, no. A7. P. 14,255–14,268.

Myagkova I.N., Shirokii V.R., Vladimirov R.D., et al. Prediction of the Dst -Index using adaptive methods. *Russian Meteorology and Hydrology*. Allerton Press Inc. 2021. Vol. 46, no. 3. P. 157–162.

Palochia G., Amota E., Consolini G., et al. Geomagnetism *Dst*-index forecast based on IMF data only. *Ann. Geophys.* 2006. Vol. 24. P. 989–999.

Stepanova M.V., Perez P. Autoprediction of *Dst*-index using neural network techniques and relationship to the auroral geomagnetics indices. *Geofisica International.* 2000. Vol. 39, no. 1. P. 143–146.

Suigiura M. Hourly values of equatorial *Dst* for the IGY. *Ann. Int. Geophys. Year.* Pergamon Press, Oxford. 1964. Vol. 35. P. 9–45.

Yashin I.I., Astapov I.I., Barbashina N.S., et al. Real-time data of muon hodoscope URAGAN. *Adv. Space Res.* 2015. Vol. 56, iss. 12. P. 2693–2705.

URL: <https://wdc.kugi.kyoto-u.ac.jp> (дата обращения 23 декабря 2023 г.).

URL: <http://www.nevod.mephi.ru/> (дата обращения 13 марта 2024 г.).

URL: <https://it.mephi.ru/hpc/performance> (дата обращения 23 декабря 2023 г.).

URL: <https://arxiv.org/abs/1905.11946/> (дата обращения 23 декабря 2023 г.).

URL: <https://arxiv.org/abs/1409.1556v6> (дата обращения 23 декабря 2023 г.).

URL: <https://arxiv.org/abs/1608.06993v5> (дата обращения 23 декабря 2023 г.).

URL: <https://arxiv.org/abs/1512.00567v3> (дата обращения 13 марта 2024 г.).

URL: <https://arxiv.org/pdf/2107.07699.pdf> (дата обращения 23 декабря 2023 г.).

URL: <https://arxiv.org/abs/1512.03385> (дата обращения 23 декабря 2023 г.).

URL: <https://arxiv.org/pdf/1412.6980.pdf> (дата обращения 23 декабря 2023 г.).

URL: <https://pytorch.org/docs/stable/generated/torch.optim.Adam.html> (дата обращения 23 декабря 2023 г.).

URL: <https://learndatasci.com/glossary/binary-classification> (дата обращения 23 октября 2023 г.).

URL: <https://www.learndatasci.com/glossary/binary-classification/> (дата обращения 13 марта 2024 г.).

URL: <https://helenkapatsa.ru/blogpost/otsienka-fl> (дата обращения 13 марта 2024 г.).

URL: <https://www.izmiran.ru/ionosphere/weather/storm/> (дата обращения 13 марта 2024 г.).

Как цитировать эту статью:

Гетманов В.Г., Гвишиани А.Д., Соловьёв А.А., Зайцев К.С., Дунаев М.Е., Ехлаков Э.В. Распознавание геомагнитных бурь на основе матричных временных рядов наблюдений мюонного годоскопа УРАГАН с использованием нейронных сетей глубокого обучения. *Солнечно-земная физика.* 2024. Т. 10, № 1. С. 83–91. DOI: [10.12737/szf-101202411](https://doi.org/10.12737/szf-101202411).