

ISSN 2500—0381

Электронная версия

ISSN 0021—3454


Печатная версия

ИЗВЕСТИЯ ВЫСШИХ УЧЕБНЫХ ЗАВЕДЕНИЙ
ПРИБОРО**С**ТРОЕНИЕ
НАУЧНО - ТЕХНИЧЕСКИЙ ЖУРНАЛ



№ **4**
Т. 67
2024

Journal of **I**nstrument **E**ngineering



ГЛАВНЫЙ РЕДАКТОР

*д-р техн. наук, проф. А. А. БОБЦОВ,
Университет ИТМО, Санкт-Петербург, Россия*

РЕДАКЦИОННАЯ КОЛЛЕГИЯ

*А. П. АЛЕШКИН, д-р техн. наук, проф., ВКА им. А. Ф. Можайского, Санкт-Петербург, Россия
А. В. БЕЛИКОВ, д-р техн. наук, проф., Университет ИТМО, Санкт-Петербург, Россия
И. А. БЕССМЕРТНЫЙ, д-р техн. наук, проф., Университет ИТМО, Санкт-Петербург, Россия
В. А. БОГАТЫРЕВ, д-р техн. наук, проф., Университет ИТМО, Санкт-Петербург, Россия
Д. В. ЕФАНОВ, д-р техн. наук, проф., СПбПУ, Санкт-Петербург, Россия
В. В. ЕФИМОВ, д-р техн. наук, проф., ВКА им. А. Ф. Можайского, Санкт-Петербург, Россия
А. КЛИМЧИК, PhD, доцент, Университет Иннополис, Иннополис, Россия
С. А. КОЛЮБИН, д-р техн. наук, доцент, Университет ИТМО, Санкт-Петербург, Россия
И. А. КОНЯХИН, д-р техн. наук, проф., Университет ИТМО, Санкт-Петербург, Россия
В. В. КРИШТОП, д-р физ.-мат. наук, проф., ПНИПУ, Пермь, Россия
Л. С. ЛИСИЦЫНА, д-р техн. наук, проф., Университет ИТМО, Санкт-Петербург, Россия
Ю. А. ЛИТВИНЕНКО, канд. техн. наук, Концерн «ЦНИИ «Электронприбор», Санкт-Петербург, Россия
В. Д. ЛУКЬЯНОВ, д-р физ.-мат. наук, проф., ОАО «Авангард», Санкт-Петербург, Россия
А. В. ЛЯМИН, д-р техн. наук, доцент, СПбПУ, Санкт-Петербург, Россия
А. В. МАЛОЛЕТОВ, д-р физ.-мат. наук, проф., Университет Иннополис, Иннополис, Россия
Ю. Н. МАТВЕЕВ, д-р техн. наук, ООО «ЦРТ-инновации», Санкт-Петербург, Россия
В. М. МЕДУНЕЦКИЙ, д-р техн. наук, проф., ООО «Феррум», Санкт-Петербург, Россия
А. Н. МИРОНОВ, д-р техн. наук, проф., ВКА им. А. Ф. Можайского, Санкт-Петербург, Россия
В. М. МУСАЛИМОВ, д-р техн. наук, проф., ИПМаш РАН, Санкт-Петербург, Россия
А. А. ОЖИГАНОВ, д-р техн. наук, проф., АО «НИТИ «Авангард», Санкт-Петербург, Россия
А. А. ПЫРКИН (зам. главного редактора), д-р техн. наук, проф., Университет ИТМО, Санкт-Петербург, Россия
В. С. СИЗИКОВ, д-р техн. наук, проф., Университет ИТМО, Санкт-Петербург, Россия
Б. В. СОКОЛОВ, д-р техн. наук, проф., СПбФИЦ РАН, Санкт-Петербург, Россия
С. В. СОЛК, д-р техн. наук, НИИ ОЭП, Сосновый Бор, Ленинградская обл., Россия
В. Ю. ТЕРТЫЧНЫЙ, д-р физ.-мат. наук, проф., Университет ИТМО, Санкт-Петербург, Россия
Д. В. ТИТОВ, д-р техн. наук, доцент, ЮЗГУ, Курск, Россия
А. В. ФЕДОРОВ, д-р техн. наук, доцент, Университет ИТМО, Санкт-Петербург, Россия
Н. Б. ФИЛИМОНОВ (зам. главного редактора), д-р техн. наук, проф., МГУ им. М. В. Ломоносова, Москва, Россия
И. Б. ФУРТАТ, д-р техн. наук, доцент, ИПМаш РАН, Санкт-Петербург, Россия
В. П. ХОДУНКОВ, канд. техн. наук, ВНИИМ им. Д. И. Менделеева, Санкт-Петербург, Россия*

Ответственный секретарь М. В. Лебецкая

Редактор Л. Г. Позднякова

Набор, верстка: М. В. Герасимова

Перевод: Ю. И. Копилевич

Адрес: 197101, Санкт-Петербург, Кронверкский пр., 49, лит. А, Университет ИТМО

Телефон: (812) 480-02-73, E-mail: pribor@itmo.ru

[http:// pribor.ifmo.ru/](http://pribor.ifmo.ru/)

Подписано в печать 12.04.2024 г.

Отпечатано в учреждении „Университетские телекоммуникации“

Адрес: 197101, Санкт-Петербург, Кронверкский пр., 49, лит. А

Телефон: (812) 915-14-54, E-mail: Prudentov@tibir.ru

Редколлегия просит авторов и рецензентов отнестись с пониманием к ужесточению требований к рукописям и изменению формы подачи материала в журнале.

Аннотация объемом 150—250 слов должна отражать содержание статьи: предмет исследования, цель работы, метод проведения работы, краткое описание экспериментальных или теоретических исследований, полученные результаты и рекомендации по их применению.

Ключевые слова, служащие идентификаторами при предметном поиске, должны однозначно отражать содержание статьи. Основное ключевое слово/словосочетание указывается первым, общее количество ключевых слов — не менее 5.

Список литературы: для обзорной статьи рекомендуется приводить не менее 50 источников, для полнотекстовой статьи — не менее 15, для краткого сообщения — не менее 8.

Требования к оформлению рукописи размещены на сайте журнала <http://pribor.itmo.ru/>



Адрес: 197101, Санкт-Петербург,
Кронверкский пр., 49, лит. А, Университет ИТМО
Телефон: (812) 480-02-73
[http:// pribor.ifmo.ru/](http://pribor.ifmo.ru/)
E-mail: pribor@itmo.ru

Журнал публикует научные обзоры, полнотекстовые статьи и краткие сообщения, отражающие результаты практических и теоретических исследований в области приборостроения.

Журнал содержит следующие разделы:

- информатика и информационные процессы;
- информационно-измерительные и управляющие системы;
- системный анализ, управление и обработка информации;
- приборы навигации;
- вычислительные системы и их элементы;
- оптические и оптико-электронные приборы и комплексы;
- приборы и методы контроля и диагностики материалов, изделий, веществ и природной среды;
- приборы, системы и изделия медицинского назначения;
- проектирование и технология приборостроения и радиоэлектронной аппаратуры;
- метрология и метрологическое обеспечение;
- компьютерное моделирование и автоматизация проектирования;
- роботы, мехатроника и робототехнические системы.

По договоренности с Редакцией может быть опубликован специальный тематический выпуск, посвященный достаточно узкой проблеме приборостроения.

Рукопись подается по электронной почте: pribor@itmo.ru. Редакция принимает рукопись к рецензированию при условии получения полного комплекта документов, включающего:

- экспертное заключение о возможности опубликования в открытой печати (формат PDF);
- файлы рукописи статьи, оформленные в соответствии с требованиями журнала;
- сведения об авторах, заполненные по шаблону (на русском и английском языке);
- договор о передаче авторских прав.

Рукопись должна содержать:

- название статьи (на русском и английском языке), индекс УДК;
- аннотацию (150—250 слов, на русском и английском языке), ключевые слова (не менее 5 и не более 25, на русском и английском языке), основной текст, список литературы;
- рисунки и таблицы.

Объем текста (оформленного в соответствии с требованиями журнала — шрифт Times New Roman, размер — 14 пт, междустрочный интервал 1,5, поля — сверху и слева 25 мм, снизу 20 мм, справа 10 мм) должен составлять 10—20 страниц, краткого сообщения — 3—5. Объем обзора предварительно согласовывается с Редакцией.

Список литературы (рекомендуется): для обзорной статьи — не менее 50, для полнотекстовой статьи — не менее 15, для краткого сообщения — не менее 8 литературных источников (не менее половины из них должны представлять собой ссылки на издания, включенные в международные базы цитирования Scopus и Web of Science). Список литературы должен формироваться в порядке появления ссылок в тексте.

Не допускается выравнивание с помощью пробелов, табуляций и символов конца абзаца. Эти символы при необходимости могут вставляться не более одного раза подряд (**не переносить с помощью дефисов**).

Формулы и отдельные символы набираются с использованием редактора формул MathType. **Не вставлять** формулы из пакетов MathCad и MatLab. Размер шрифта в формулах — по умолчанию. Все переменные набираются курсивом, греческие буквы — прямым шрифтом, полужирные символы в формуле — стилем „матрица вектор“, русские символы — стилем „текст“, векторы следует набирать полужирным шрифтом без стрелок.

Рисунки выполняются в градациях серого в одном из форматов приложений Microsoft (Word, Excel, PowerPoint), предпочтителен векторный формат. Кривые на графиках следует помечать цифрами (1, 2, 3 и т.д.) или/и задавать линиями разного стиля (пунктир, штрихпунктир, жирная); толщина осей должна быть не менее 0,5 пт, иначе качество печати не гарантируется.

Плата за публикацию не взимается.

СОДЕРЖАНИЕ

СИСТЕМНЫЙ АНАЛИЗ, УПРАВЛЕНИЕ И ОБРАБОТКА ИНФОРМАЦИИ

- Акопян Б. К. Классификация эпизодов нарушений сердечного ритма по информативным признакам во временной области электрокардиограммы.....305
- Раскопина А. С., Боженко В. В., Татарникова Т. М. Использование глубокого обучения при диагностировании пневмонии по рентгеновским снимкам.....315
- Боженко В. В., Черныш Н. Ю., Татарникова Т. М. Интеллектуальный анализ данных в диагностике анемии по клиническим показателям.....321
- Мокрецов Н. С., Архипцев Е. Д. Методы оптимизации моделей нейронных сетей330

ИНФОРМАТИКА И ИНФОРМАЦИОННЫЕ ПРОЦЕССЫ

- Булгаков Д. А. Генерация случайных чисел для интерактивных приложений с использованием внешних датчиков338
- Архипцев Е. Д., Мокрецов Н. С. Методы балансировки нагрузки в информационных системах.....345
- Аксенов А. В. Балансируемая структура данных с приоритетами элементов в задаче моделирования дискретных источников информации352

МЕТОДЫ И ПРИБОРЫ ДЛЯ АНАЛИЗА И КОНТРОЛЯ МАТЕРИАЛОВ, ИЗДЕЛИЙ, ВЕЩЕСТВ И ПРИРОДНОЙ СРЕДЫ

- Чичкова Е. Ф., Хамедов В. А., Рогачев С. А. Исследование изменчивости природно-территориальных комплексов Тазовского полуострова на основе данных многоспектральной и радиолокационной космической съемки359
- Пострыбайло М. В., Татарникова Т. М. Модельные оценки параметров пассивных радиотехнических систем мониторинга грозовой активности.....368

КРАТКИЕ СООБЩЕНИЯ

- Чичкова Е. Ф., Кочин Д. А., Рогачев С. А. Информационно-аналитический сервис: подход к анализу геопространственных данных спутникового мониторинга.....375

EDITOR-IN-CHIEF

*Dr. Sci., Prof. ALEXEY BOBTSOV,
ITMO University, St. Petersburg, Russia*

EDITORIAL BOARD

*ALESHKIN ANDREY, Dr. Sci., Prof., A. F. Mozhaisky Military Space Academy, St. Petersburg, Russia
BELIKOV ANDREY, Dr. Sci., Prof., ITMO University, St. Petersburg, Russia
BESSMERTNY IGOR, Dr. Sci., Prof., ITMO University, St. Petersburg, Russia
BOGATYREV VLADIMIR, Dr. Sci., Prof., ITMO University, St. Petersburg, Russia
EFANOV DMITRY, Dr. Sci., Prof., SPbPU, St. Petersburg, Russia
EFIMOV VLADIMIR, Dr. Sci., Prof., A. F. Mozhaisky Military Space Academy, St. Petersburg, Russia
KHODUNKOV VYACHESLAV, PhD, D. I. Mendeleev All-Russian Institute for Metrology, St. Petersburg, Russia
KLIMCHIK ALEXANDER, PhD, Ass. Prof., Innopolis University, Innopolis, Russia
KOLYUBIN SERGEY, Dr. Sci., Ass. Prof., ITMO University, St. Petersburg, Russia
KONYAKHIN IGOR, Dr. Sci., Prof., ITMO University, St. Petersburg, Russia
KRISHTOP VIKTOR, Dr. Sci., Prof., PNRPU, Perm, Russia
LISITSYNA LYUBOV, Dr. Sci., Prof., ITMO University, St. Petersburg, Russia
LITVINENKO YULIA, PhD, Concern CSRI Electropribor, JSC, St. Petersburg, Russia
LUKYANOV VALERY, Dr. Sci., Prof., Avangard JSC, St. Petersburg, Russia
LYAMIN ANDREY, Dr. Sci., Ass. Prof., SPbPU, St. Petersburg, Russia
MALOLETOV ALEXANDER, Dr. Sci., Prof., Innopolis University, Innopolis, Russia
MATVEEV YURIY, Dr. Sci., Speech Technology Center, St. Petersburg, Russia
MEDUNETSKY VIKTOR., Dr. Sci., Prof., Ferrum LLC, St. Petersburg, Russia
MIRONOV ANDREY, Dr. Sci., Prof., A. F. Mozhaisky Military Space Academy, St. Petersburg, Russia
MUSALIMOV VIKTOR, Dr. Sci., Prof., IPMash RAS, St. Petersburg, Russia
OZHIGANOV ALEXANDER, Dr. Sci., Prof., SRTI Avangard JSC, St. Petersburg, Russia
PYRKIN ANTON, Dr. Sci., Prof., Deputy Editor-in-Chief, ITMO University, St. Petersburg, Russia
SIZIKOV VALERY, Dr. Sci., Prof., ITMO University, St. Petersburg, Russia
SOKOLOV BORIS, Dr. Sci., Prof., SPbFRC RAS, St. Petersburg, Russia
SOLK SERGEY, Dr. Sci., SRI OEP, Sosnovy Bor, Leningrad region, Russia
TERTYCHNY VLADIMIR, Dr. Sci., Prof., ITMO University, St. Petersburg, Russia
TITOV DMITRY, Dr. Sci., Ass. Prof., SWSU, Kursk, Russia
FEDOROV ALEXEY, Dr. Sci., Ass. Prof., ITMO University, St. Petersburg, Russia
FILIMONOV NIKOLAY, Dr. Sci., Prof., Deputy Editor-in-Chief, M. V. Lomonosov MSU, Moscow, Russia
FURTAT IGOR, Dr. Sci., Ass. Prof., IPMash RAS, St. Petersburg, Russia*

Executive secretary Marina V. Lebetskaya

Editor Lidia G. Pozdniakova

Page-proof, makeup Maria V. Gerasimova

Translation of Yuriy I. Kopilevich

Address: ITMO University, Kronverksky pr. 49, bldg. A, St. Petersburg, Russia, 197101

Tel: (812) 480-02-73

Site: pribor.ifmo.ru

E-mail: pribor@itmo.ru

JOURNAL OF INSTRUMENT ENGINEERING

ITMO UNIVERSITY

The Journal is published since January 1958

Vol. 67

APRIL 2024

№ 4

CONTENTS

SYSTEM ANALYSIS, CONTROL, AND INFORMATION PROCESSING

- Akopyan B. K.** Classification of Heart Rhythm Disorder Episodes by Informative Features in the Electrocardiogram Time Domain305
- Raskopina A. S., Bozhenko V. V., Tatarnikova T. M.** Using Deep Learning in Pneumonia Diagnosis from X-rays Patterns.....315
- Bozhenko V. V., Chernysh N. Yu., Tatarnikova T. M.** Data Mining in the Diagnosis of Anemia by Clinical Indicators.....321
- Mokretsov N. S., Arkhipsev E. D.** Methods for Optimizing Neural Network Models330

INFORMATICS AND INFORMATION PROCESSES

- Bulgakov D. A.** Random Number Generation for Interactive Applications Using External Sensors.....338
- Arkhipsev E. D., Mokretsov N. S.** Methods of Load Balancing in Highly Loaded Systems.....345
- Aksenov A. V.** Balanceable Data Structure with Element Priorities in the Problem of Discrete Information Source Modeling352

METHODS AND INSTRUMENTS FOR ANALYSIS AND MONITORING OF THE NATURAL ENVIRONMENT, SUBSTANCES, MATERIALS AND PRODUCTS

- Chichkova E. F., Khamedov V. A., Rogachev S. A.** Study of the Variability of Natural-Territorial Complexes of the Taz Peninsula Based on Multispectral and Radar Space Survey Data359
- Postrybaylo M. V., Tatarnikova T. M.** Model Estimates of Parameters of Passive Radio Systems for Monitoring Lightning Activity368

BRIEF NOTES

- Chichkova E. F., Kochin D. A., Rogachev S. A.** Information and Analytical Service: Approach to Analyzing Geospatial Data from Satellite-based Monitoring.....375

To the Authors!

The Journal of Instrument Engineering publishes scientific reviews, full-text articles and short messages, reflecting the unpublished results of theoretical and practical research in the field of fundamental instrument making.

The Journal publishes articles on the following themes: information technologies and systems, devices and automatic control systems, computer engineering, gyroscopic and navigation systems, instruments of precision mechanics, electronic and electromagnetic devices, optical and optoelectronic devices and systems, thermal regimes and reliability of devices and systems, technology and instrumentation, scientific and practical development. In agreement with the Editorial Board can be published a special themed issue devoted to a fairly narrow issue of instrumentation.

The material of the article accepted in electronic form and on any media, executed in a text editor Word without formatting along with a hard copy on A4. Electronic version of the paper may be sent by E-mail: **pribor@mail.ifmo.ru**

The size of the article (in printed form) must not exceed eight pages, a short presentation of two. Size scientific review previously agreed with the Editorial Board.

Submission includes two copies of:

— the manuscript text; list of references (recommended): review article — not less than 50, for the full text of the article — no less than 15, for short messages — at least 8 of the literary source (at least half of them should be links to the editions listed in international database of citation Scopus and Web of Science); number citations consecutively as they appear in the text;

— extended abstract (150—250 words);

— keywords (not less than 5 and not more than 25);

— illustrations: each on a separate sheet of A4 (not overestimate in the text) — big, with a maximum fill;

— the recommendation of the Department (laboratory);

— information about the authors on a template (surname, name, patronymic, name of the organization in accordance with the latest edition of the Charter, the address of the organization, academic degree and title, position, e-mail address).

The article must also enclose agreement on the transfer of copyright.

The main text. The following requirements are common to good practice in the design documents.

Font — Times New Roman, size 14, line spacing 1.5, margins — top and left — 25 mm, bottom — 20 mm, right — 10 mm.

Not allowed alignment with spaces, tabs and end of a paragraph (in the layout will need to be cleared). These symbols must be inserted only when necessary, and not more than once in a row (not to carry with dashes).

Don't insert formulas from MathCad or MatLab!

Figures and tables are to be inserted after the list of references. Graphics are accepted in one of Microsoft formats (Word, Excel, and PowerPoint); vector format is preferable. Don't use color graphics; it is better to apply dotted, dash-and dot lines, etc., or mark lines with numerical symbols.

Editorial Staff

КЛАССИФИКАЦИЯ ЭПИЗОДОВ НАРУШЕНИЙ СЕРДЕЧНОГО РИТМА
ПО ИНФОРМАТИВНЫМ ПРИЗНАКАМ
ВО ВРЕМЕННОЙ ОБЛАСТИ ЭЛЕКТРОКАРДИОГРАММЫ

Б. К. АКОПЯН

*Санкт-Петербургский государственный университет аэрокосмического приборостроения
Санкт-Петербург, Россия
akopyan.bella@yandex.ru*

Аннотация. Исследованы особенности классификации нарушений сердечного ритма по сигналу одного отведения электрокардиограммы. Предложено первичное множество из восьми информативных признаков: три для длительности RR-интервала и пять — для формы R-зубца. Найдена эффективная комбинация предложенных признаков для классификации трех состояний сердечного ритма (нормальный кардицикл, желудочковая экстрасистола, предсердная экстрасистола) с помощью алгоритмов логистической регрессии и случайного леса. Для проведения экспериментальных исследований использовались записи отведения II из баз данных многоканальных электрокардиограмм MIT-BIH Arrhythmia DB и Санкт-Петербургского Института кардиологической техники. Определено, что наиболее информативными признаками для рассматриваемых классов нарушений сердечного ритма являются коэффициент сцепления ξ_{R_i} и коэффициент эксцесса i -го R-зубца γ_i . Достигнутая наибольшая точность классификации по средней сбалансированной F-мере для набора данных без балансировки классов составляет 92,58 % в случае логистической регрессии и 92,11 % — случайного леса; с балансировкой — 86,17 % для логистической регрессии и 84,55 % — для случайного леса. Результаты экспериментов показывают, что для классификации рассматриваемых нарушений сердечного ритма целесообразно использовать по одному критерию из признаков длительности и формы. Полученные в ходе экспериментальных исследований результаты могут быть применены при синтезе и анализе систем классификации нарушений сердечного ритма.

Ключевые слова: пространство информативных признаков, многоклассовая классификация, электрокардиограмма, нарушение сердечного ритма, анализ данных

Ссылка для цитирования: Акопян Б. К. Классификация эпизодов нарушений сердечного ритма по информативным признакам во временной области электрокардиограммы // Изв. вузов. Приборостроение. 2024. Т. 67, № 4. С. 305—314. DOI: 10.17586/0021-3454-2024-67-4-305-314.

CLASSIFICATION OF HEART RHYTHM DISORDER EPISODES
BY INFORMATIVE FEATURES
IN THE ELECTROCARDIOGRAM TIME DOMAIN

B. K. Akopyan

*St. Petersburg State University of Aerospace Instrumentation, St. Petersburg, Russia
akopyan.bella@yandex.ru*

Abstract. The features of heart rhythm disturbances classification based on the electrocardiogram obtained from one lead are studied. A primary set of eight informative features is proposed: three for the RR-interval duration and five for the R-waveshape. An effective combination of the proposed features for classification of three states of heart rhythm (normal cardio cycle, ventricular extrasystole, atrial extrasystole) using algorithms of logistic regression and random forest is proposed. The records of II lead from multi-channel electrocardiograms databases of MIT-BIH Arrhythmia DB and

St.-Petersburg Institute of Cardiological Engineering „INCART“ are applied. It is found that the most informative features for the considered classes of cardiac rhythm disorders are the clutch coefficient ξ_{R_i} and the i -th R -wave kurtosis coefficient γ_i . The best accuracy of classification according to the average balanced F-measure for dataset without class balancing is 92.58 % for logistic regression and 92.11 % for random forest; with class balancing the result is 86.17 % for logistic regression and 84.55 % for random forest. The experimental results show that to classify the heart rhythm disturbances under consideration, it is advisable to use one criterion of duration and form. The obtained results can be used in the synthesis and analysis of classification systems for heart rhythm disorders.

Keywords: space of informative features, multiclass classification, electrocardiogram, cardiac arrhythmia, data analysis

For citation: Akopyan B. K. Classification of heart rhythm disorder episodes by informative features in the electrocardiogram time domain. *Journal of Instrument Engineering*. 2024. Vol. 67, N 4. P. 305—314 (in Russian). DOI: 10.17586/0021-3454-2024-67-4-305-314.

Введение. Современные тенденции в медицинской диагностике направлены на распознавание состояния человека путем автоматизированного компьютерного анализа биомедицинских сигналов. Конечная цель анализа большинства биомедицинских сигналов заключается в классификации принятого сигнала и выдаче диагностического решения о состоянии обследуемого. Одной из задач классификации является выявление нарушения сердечного ритма, которое впоследствии может быть усовершенствовано до возможности предсказания состояния человека по имеющемуся сигналу электрокардиограммы (ЭКГ).

Целью настоящей статьи является определение эффективной комбинации информативных признаков для классификации трех состояний сердечного ритма (нормальный кардиоцикл, желудочковая экстрасистола, предсердная экстрасистола) по сигналу ЭКГ, под эффективностью при этом понимается достижение наибольшей точности определения состояния кардиоцикла. Научная новизна статьи заключается в нахождении комбинации информативных признаков для сигнала одноканальной электрокардиограммы, обеспечивающей максимальную точность классификации алгоритмами логистической регрессии и случайного леса. Результаты, полученные в ходе экспериментальных исследований, могут быть применены при синтезе и анализе систем классификации нарушений сердечного ритма.

Постановка задач классификации и отбора признаков. Исходные данные представляют собой запись сигнала электрокардиограммы, подвергнутого предобработке, заключающейся в фильтрации сигналов помехи и выделении опорных точек кардиоциклов. Подробно методы предобработки ЭКГ и выделения R -зубца рассмотрены в работах [1—3]. Как показано в статьях [4—7], для обнаружения аритмии основной, и зачастую единственной, опорной точкой временного ряда ЭКГ является положение R -зубца кардиоцикла, по которому определяется RR -интервал — длительность сигнала ЭКГ между появлениями двух смежных R -зубцов:

$$RR_i = t(R_i) - t(R_{i-1}) = (n_{R_i} - n_{R_{i-1}})T_\Delta, \quad (1)$$

где RR_i — текущий RR -интервал, R_i — R -зубец текущего кардиоцикла, R_{i-1} — R -зубец предыдущего кардиоцикла, $t(R)$ — временное положение вершины R -зубца, T_Δ — период дискретизации, n — порядковый номер отсчета. Также, зная положение R -зубца, можно определить значения отсчетов сигнала s кардиоцикла в его окрестности.

Рассмотрим постановку задачи многоклассовой классификации нарушения ритма по сигналу электрокардиограммы. По опорной точке R_i определяются информативные признаки кардиоцикла так, что каждый кардиоцикл описан в общем случае набором из n информативных признаков $\Theta_i = (\theta_1, \theta_2, \dots, \theta_n)$. Известно, что истинное состояние (класс) кардиоцикла может быть

отнесено только к одному из M классов, представленных множеством $\Omega = \{\Omega_1, \Omega_2, \dots, \Omega_M\}$. Для успешного решения этой задачи необходимо определить:

- 1) n -мерное пространство признаков,
- 2) границы разделяющих поверхностей областей каждого из классов в n -мерном пространстве признаков,
- 3) положение точки Θ в n -мерном пространстве признаков $\mathbb{R}^n$.

Задача отбора признаков заключается в поиске на множестве $\mathbb{R}$ такого подмножества признаков $\mathbb{R}^n$, которое не приведет к существенному снижению точности классификации или, напротив, увеличит ее.

Сложность задачи многоклассовой классификации кардиоциклов по ЭКГ заключается в присущих всем биомедицинским сигналам разнообразию и изменчивости признаков нарушений ритма, возникающих вследствие того, что организм человека является сложной системой. Вследствие этого с ростом числа классифицируемых нарушений ритма возрастет и размерность пространства информативных признаков. Как показано в работах [8, 9], эта проблема особенно актуальна при анализе ЭКГ с длительными нарушениями (например, при парных экстрасистолах или мерцательной аритмии).

При большом количестве информации, поступающей на вход системы классификации, выбор признаков является необходимым и зачастую наиболее важным этапом, поскольку успешное решение задачи отбора признаков позволит снизить размерность вектора измерений и описания объектов, а также повысить эффективность системы классификации в целом.

Построение признаков. Для определения потенциально применимых в исследовании признаков целесообразно обратиться к ЭКГ-признакам аритмий. Как правило, все аритмические кардиоциклы отличаются от нормальных длительностью RR-интервала и формой полезного сигнала кардиограммы. На рис. 1 приведены примеры ЭКГ для трех классов: Ω_1 — нормальный кардиоцикл, Ω_2 — желудочковая экстрасистола, Ω_3 — предсердная экстрасистола.




Рис. 1

Для предсердной экстрасистолы характерна неполная компенсаторная пауза, которую можно выразить с помощью соотношения:

$$RR_i + RR_{i+1} < 2\overline{RR}, \quad (2)$$

где RR_i — длительность временного интервала между текущим и предшествующим кардиоциклами (для экстрасистолы — так называемый „интервал сцепления“), RR_{i+1} — длительность временного интервала между текущим и последующим кардиоциклами (для экстрасистолы — так называемая „компенсаторная пауза“), $\overline{RR}$ — средняя длительность RR-интервала при нормальном ритме. Форма R-зубца при предсердной экстрасистолии практически не претерпевает изменений.

Для желудочковой экстрасистолии характерны полная компенсаторная пауза:

$$RR_i + RR_{i+1} \approx 2\overline{RR}, \quad (3)$$

а также расширение и деформация как R-зубца, так и всего кардиоцикла.

Исходя из ЭКГ-признаков рассматриваемых состояний можно выделить признаки, характеризующие длительность RR-интервалов и форму R-зубца.

Целесообразно исследовать следующие признаки длительности:

1) отношения смежных RR-интервалов. Поскольку для рассматриваемых нарушений сердечного ритма имеют значение как интервал сцепления, так и компенсаторная пауза, следует выделить два потенциально значимых признака.

1.1. Коэффициент сцепления ξ_{R_i} , отражающий отношение текущего RR-интервала (потенциального интервала сцепления) к предыдущему:

$$\xi_{R_i} = \frac{RR_i}{RR_{i-1}}. \quad (4)$$

1.2. Коэффициент компенсаторной паузы $\xi_{R_{i+1}}$, отражающий отношение последующего RR-интервала (потенциальной компенсаторной паузы) к предыдущему:

$$\xi_{R_{i+1}} = \frac{RR_{i+1}}{RR_{i-1}}, \quad (5)$$

где RR_{i-1} — длительность RR-интервала, предшествующего предыдущему кардиоциклу. Предполагается, что данные признаки должны обеспечить успешную классификацию одиночных экстрасистол, однако для парных эпизодов могут быть неэффективны;

2) разность отклонения RR-интервалов на скользящем окне $\Delta\sigma_{RR_i}$:

$$\Delta\sigma_{RR_i} = \sigma_{RR_i} - \sigma_{RR_{i-1}}, \Delta\sigma_{RR_i} = \sqrt{\frac{1}{L-1} \sum_{j=1}^L (RR_j - \overline{RR})^2}, \overline{RR} = \frac{1}{L} \sum_{j=1}^L RR_j, \\ \Delta\sigma_{RR_i} = \sigma_{RR_i} - \sigma_{RR_{i-1}}, \Delta\sigma_{RR_i} = \sqrt{\frac{1}{L-1} \sum_{j=1}^L (RR_j - \overline{RR})}, \overline{RR} = \frac{1}{L} \sum_{j=1}^L RR_j, \quad (6)$$

где L — длина скользящего окна, σ_{RR_i} — среднеквадратическое отклонение выборки из L RR-интервалов с включением текущего кардиоцикла, $\Delta\sigma_{RR_{i-1}}$ — среднеквадратическое отклонение выборки из L RR-интервалов, предшествующих текущему кардиоциклу. Этот информативный признак „унаследован“ из практики анализа статистических характеристик variability сердечного ритма показателями SDNN и SDANN. SDNN представляет собой среднеквадратическое отклонение величин RR-интервалов за весь рассматриваемый период наблюдения сердечного ритма; SDANN — среднеквадратическое отклонение величин RR-интервалов на коротких сегментах многочасовых записей. Подробно эти признаки рассмотрены в статье [10].


Применительно к рассматриваемой задаче классификации эпизодов нарушений сердечного ритма использование среднеквадратического отклонения также представляется целесообразным, однако исходя из того, что нарушению ритма соответствует резкое изменение длительности RR-интервала, следует вычислять этот показатель на скользящем окне длиной в несколько RR-интервалов. Длина скользящего окна была выбрана равной $L = 5$ [11].

В категории признаков формы R-зубца, полученных по временному ряду ЭКГ, исходя из ЭКГ-признаков нарушения ритма, исследуются следующие признаки.

1. Средняя амплитуда i -го R-зубца R_i :

$$\bar{R}_i = \frac{\sum_{j=1}^n s_j T_{\Delta}}{(n_2 - n_1) T_{\Delta}} = \frac{\sum_{j=1}^n s_j}{n_2 - n_1} = \frac{\sum_{j=1}^n s_j}{N_R}, \quad (7)$$

где s_i — отсчеты сигнала R-зубца, расположенные между отсчетами n_1, n_2 кардиоцикла, расположенными на уровне изолинии (рис. 2), N_R — объем выборки исследуемого фрагмента R-зубца.



2. Длительность i -го R-зубца T_{R_i} :

$$T_{R_i} = (n_2 - n_1) T_{\Delta} = N_R T_{\Delta}. \quad (8)$$

Параметры „амплитуда“ и „длительность“ можно применять как по отдельности, так и в виде их произведения.

3. Коэффициент эксцесса i -го R-зубца γ_i :

$$\gamma_i = \frac{\mu_4}{\sigma_s^4}, \mu_4 = \sum_{j=1}^{N_s} \left(\left(n_j - \bar{n} \right) T_{\Delta} \right)^4 \frac{s_j^2}{\sum_{j=1}^{N_s} s_j^2}, \quad (9)$$

где μ_4 — оценка центрального момента четвертого порядка, σ_s — оценка выборочной дисперсии R-зубца.

4. Коэффициент формы i -го R-зубца F_i :

$$F_i = \frac{\sigma_{s''}}{\sigma_s}, \quad (10)$$

где σ_s и $\sigma_{s''}$ — оценка выборочной дисперсии R-зубца и его второй производной соответственно.

Приведенные выше параметры формы характеризуют R-зубец без учета схожести с другими R-зубцами в той же записи. Целесообразно ввести также признак, отражающий степень схожести двух смежных кардиоциклов. Для этого можно использовать отношение рассмотренных параметров или ввести дополнительный параметр.

5. Коэффициент корреляции смежных R-зубцов:

$$\rho_i = \frac{\sum_{j=1}^{N_s} (s_{i,j} - m_i) \sum_{j=1}^{N_s} (s_{i-1,j} - m_{i-1})}{\sqrt{\sum_{j=1}^{N_s} (s_{i,j} - m_i)^2 \sum_{j=1}^{N_s} (s_{i-1,j} - m_{i-1})^2}}, i = 1, 2, \dots, N_s, \quad m_i = \frac{1}{N_s} \sum_{j=1}^n s_{i,j}, \quad m_{i-1} = \frac{1}{N_s} \sum_{j=1}^n s_{i-1,j}, \quad (11)$$

где s_{i-1} — выборка отсчетов сигнала предыдущего R-зубца, j — порядковый номер отсчета.

Данный параметр наилучшим образом отражает степень схожести двух смежных кардиоциклов. Очевидно: чем меньше коэффициент корреляции, тем выше вероятность того, что они относятся к разным классам. Этот признак должен быть наиболее полезен в определении одиночных желудочковых экстрасистол.

Материалы и методы. Принято различать два класса методов отбора признаков: методы фильтрации и обертки. Метод фильтрации отражает информативность каждого признака для целевой переменной в отрыве от системы классификации и анализирует определенные метрики самих информативных признаков: энтропию, коэффициент корреляции, распределение вероятностей, дисперсию, взаимную информацию и др. Их достоинство заключается в высокой скорости выполнения и возможности масштабирования.

Методы обертки служат оболочкой системы классификации. Принцип их работы заключается в манипуляции набором информативных признаков и оценке результата классификации, по которому определяют наиболее эффективное подмножество для конкретного классификатора. Как показано в статье [12], эти группы методов учитывают синергетический эффект от совместного использования отобранных признаков, однако их работа требует больше времени.

Выделяют также гибридные методы, выполняющие отбор признаков в несколько этапов, примеры подобных методов и алгоритмов на их основе рассмотрены в работах [12—14]. В рамках таких методов фильтры используются для первичного отбора признаков, после чего полученное подмножество признаков подается в систему „обертка—классификатор“ и по результатам работы этой системы производится вторичный отбор признаков. Как показано в статье [14], такой подход целесообразен, если первичное множество состоит не менее чем из нескольких десятков признаков. Также важно отметить, что некоторые алгоритмы классификации (например, алгоритм случайного леса) осуществляют собственную внутреннюю оценку признаков [15].

В настоящем исследовании используются системы классификации с обучением на основе алгоритмов логистической регрессии (LR) и случайного леса (RF). Каждый из них исследован на предмет сокращения размерности информационного пространства путем отбора наиболее важных признаков. Отбор признаков для классификации алгоритмом логистической регрессии осуществляется оберточным методом рекурсивного удаления RFE [16]. На вход классификатора подаются все имеющиеся признаки, производятся обучение алгоритма и дальнейшая классификация, по результатам которой из множества признаков удаляется один. Все признаки ранжируются по очередности их удаления. Классификация алгоритмом случайного леса осуществляется по результатам оценки важности признаков внутри самого алгоритма при подаче на его вход всего множества признаков. По результатам обоих независимых отборов определены пары признаков, показатели важности которых оказались наиболее высокими, и для каждой пары отдельное исследование показателя качества.

Исследование проводилось на материалах отведения II двух открытых баз данных:

1) верифицированная база данных MIT-BIH Arrhythmia DB [17], которая содержит 48 получасовых записей ЭКГ от 47 различных пациентов. 23 записи выбраны случайным образом из набора 4000 записей ЭКГ, сделанных в течение 24 часов, собранных у смешанной группы стационарных и амбулаторных пациентов. Остальные 25 записей выбраны из того же набора для включения менее распространенных, но клинически значимых аритмий. Частота дискретизации записей составляет 360 Гц. Каждая запись аннотирована двумя или более независимыми кардиологами.

2) база данных многоканальных ЭКГ Санкт-Петербургского Института кардиологической техники (ИНКАРТ, INCART) [18], которая содержит 75 получасовых записей результатов холтеровского мониторинга ЭКГ 32 различных пациентов с частотой дискретизации записей 257 Гц.

Соотношение классов представлено на рис. 3 (K — число кардиоциклов). Имеющийся набор данных был разделен на обучающую и тестовую выборки в соотношении 3:1 (136 576 обучающих и 45 525 тестовых кардиоциклов). Важно отметить, что имеющиеся в обеих базах классы несбалансированы ($\Omega_3 < \Omega_2 < \Omega_1$), что, с одной стороны, отражает реальное соотношение состояний, а с другой — может привести к нарушению работы классификатора и его переобучению. В связи с этим было принято решение о дополнительном исследовании влияния балансировки классов методом недостаточной выборки (т.е. посредством случайного исключения наблюдений из мажоритарного класса) на результаты отбора признаков.




Рис. 3

Результаты экспериментальных исследований. Всего было обработано 182 101 кардиоциклов, принадлежащих трем классам состояний. Результаты отбора признаков представлены на рис. 4, 5 (r — ранг; W — показатель важности).




Рис. 4




Рис. 5

По результатам отбора видно, что первые четыре по важности признака у обоих алгоритмов совпали как до, так и после балансировки:

- 1) коэффициент сцепления ξ_{R_i} ,
- 2) коэффициент эксцесса i -го R-зубца γ_i ,
- 3) коэффициент формы i -го R-зубца F_i ,
- 4) разность отклонения RR-интервалов на скользящем окне $\Delta\sigma_{RR_i}$.

Из этого можно сделать вывод, что для данных классов нарушений сердечного ритма эти признаки являются наиболее информативными.

Было принято решение объединить ЭКГ-признаки рассматриваемых классов в пары, состоящие из одного признака длительности и одного признака формы, после чего для каждой пары были оценены показатели качества. Результаты оценки приведены в таблице. В роли показателя качества классификации выступает сбалансированная F-мера:

$$F = 2 \frac{P \cdot R_c}{P + R_c}, \quad (12)$$

где P — точность, R_c — полнота F-меры:

$$P = \frac{TP}{TP+FP}, \quad R_c = \frac{TP}{TP+FN}, \quad (13)$$

где TP — число истинно-положительных решений, TN — число истинно-отрицательных решений, FP — число ложноположительных решений, FN — число ложноотрицательных решений.

Признак длительности	Признак формы	MIT-BIH Arrhythmia				INCART			
		до балансировки		после балансировки		без балансировки		с балансировкой	
		LR	RF	LR	RF	LR	RF	LR	RF
$\xi_{R_{i-1}}$	$F_i, \%$	91,93	84,62	83,24	78,95	91,80	90,53	84,12	81,34
	$\gamma_i, \%$	92,17	91,24	86,01	84,39	92,98	92,11	86,33	84,71
$\Delta\sigma_{RR_i}$	$F_i, \%$	82,34	81,77	77,49	65,12	82,07	80,26	78,92	74,93
	$\gamma_i, \%$	88,91	84,98	79,56	72,52	88,91	85,38	76,28	66,74

По результатам, приведенным в таблице, видно, что наиболее информативными признаками для рассматриваемых классов нарушений сердечного ритма являются коэффициент сцепления ξ_{R_i} и коэффициент эксцесса i -го R-зубца γ_i . Достигнутая для этой пары признаков точность классификации по средней сбалансированной F-мере для набора данных без балансировки классов равна 92,58 % для логистической регрессии и 92,11 % — для случайного леса; с балансировкой точность составляет 86,17 % для логистической регрессии и 84,55 % — для случайного леса.

Также из таблицы видно, что показатели для обеих баз данных примерно совпадают. Превышение значений, полученных по выборке без балансировки, незначительно. В этом случае классификатор ориентирован на обнаружение того класса, образцов которого в обучающей выборке было больше — т.е. класса нормальных ЭКГ Ω_1 .

Заключение. Рассмотрен набор информативных признаков, который применим для определения трех классов состояния сердечного ритма (нормальный кардиоцикл, желудочковая экстрасистола, предсердная экстрасистола) по сигналу электрокардиограммы. В ходе вычислительных экспериментов получены результаты классификации нарушений сердечного ритма по различным комбинациям информативных признаков сигнала одноканальной электрокардиограммы и определена сбалансированная F-мера для каждой комбинации при использовании этих признаков в алгоритмах классификации. Вычислительный эксперимент демонстрирует, что наиболее эффективно для данного множества классов использование комбинации параметров „коэффициент сцепления“ и „эксцесс“.

В дальнейшем целесообразно изучить показатели зависимости информативных признаков между отведениями, а также применять эти признаки для классификации аритмических эпизодов внутри уже обозначенных классов (например, определение наджелудочковых, левожелудочковых и правожелудочковых экстрасистол).

СПИСОК ЛИТЕРАТУРЫ

1. Sun K. K., Xie C.-X., Kuo I.-C. et al. A Method for ECG R-wave Denoising and Detecting // IEEE Intern. Conf. on Consumer Electronics. 2022. P. 557—558.
2. Razavi S. R., Mohammadi M. H. D. R-peak Detection in Electrocardiogram Signals Using Continuous Wavelet Transform // Intern. J. Bioautomation. 2017. Vol. 21, N 2. P. 165—178.
3. Rakshit M., Panigrahy D., Sahu P. An improved method for R-peak detection by using Shannon energy envelope // Sadhana. 2016. Vol. 41, N 5. P. 469—477.
4. Bouchouareb R., Ferroudji K. Classification of ECG Arrhythmia using Artificial Intelligence techniques (RBF and SVM) // 4th Intern. Conf. on Pattern Analysis and Intelligent Systems (PAIS). 2022. P. 1—7.
5. Vadillo-Valderrama A., Goya-Esteban R., Caulier-Cisterna R. P. et al. Differential Beat Accuracy for ECG Family Classification Using Machine Learning // IEEE Access. 2022. Vol. 10. P. 129362—129381.
6. Nasim A., Nchekwube D. C., Munir F. et al. An Evolutionary-Neural Mechanism for Arrhythmia Classification with Optimum Features Using Single-Lead Electrocardiogram // IEEE Access. 2022. Vol. 10. P. 99050—99065.
7. Pradeepkumar A., Kaul A. ECG Arrhythmia Classification Using Ensemble of Features // 2nd Asian Conf. on Innovation in Technology (ASIANCON). 2022. P. 1—6.
8. Wang L. H., Yan Z. H., Yang Y. T. et al. A Classification and Prediction Hybrid-Model Construction with IQPSO-SVM Algorithm for Atrial Fibrillation Arrhythmia // Sensors. 2021. Vol. 19, N 21. P. 5222.
9. Соколова А. А. О распределении отношения соседних RR-интервалов в норме и при возникновении аритмии // Изв. СПбГЭТУ ЛЭТИ. 2012. Вып. 5. С. 112—118.
10. Алиева А. М., Голухова Е. З., Пинчук Т. В. Вариабельность сердечного ритма при хронической сердечной недостаточности (литературный обзор) // Архив внутренней медицины. 2013. № 6. С. 47—52.
11. Акопян Б. К., Жаринов О. О. Разработка и исследование показателей качества алгоритма обнаружения и классификации нарушений сердечного ритма // Обработка, передача и защита информации в компьютерных системах: Сб. докл. Второй Междуна. науч. конф. Санкт-Петербург, 11—15 апреля 2022. СПб: ГУАП, 2022. С. 15—18.

12. Ходашинский И. А., Сарин К. С. Отбор классифицирующих признаков с помощью популяционного случайного поиска с памятью // Автоматика и телемеханика. 2019. № 2. С. 161—172.
13. Гончаров Ю. В., Мучник И. Б., Шварцер Л. В. Алгоритм выбора признаков в задаче обучения классификации методом опорных векторов // Журнал вычислительной математики и математической физики. 2008. Т. 48, вып. 7. С. 1318—1336.
14. Глумов Н. И., Мясников Е. В. Метод отбора информативных признаков на цифровых изображениях // Компьютерная оптика. 2007. № 3. С. 73—76.
15. Картиев С. Б., Курейчик В. М. Алгоритм классификации, основанный на принципах случайного леса, для решения задачи прогнозирования // Программные продукты и системы. 2016. Т. 114, вып. 2. С. 11—15.
16. Попов Н. В., Размочаева Н. В., Клионский Д. М. Исследование алгоритмов снижения размерности пространства признаков в задаче анализа клиентских данных // Наука настоящего и будущего. 2020. С. 31—36.
17. Moody G. B., Mark R. G. The impact of the MIT-BIH Arrhythmia Database // IEEE Engineering in Medicine and Biology. 2001. Vol. 20, N 3. P. 45—50.
18. St. Petersburg INCART 12-lead Arrhythmia Database. 2008 [Электронный ресурс]: <<https://physionet.org/content/incartdb/1.0.0/>>. (дата обращения 15.01.2024).

Сведения об авторе

Белла Кареновна Акопян

— Санкт-Петербургский университет аэрокосмического приборостроения, кафедра прикладной информатики; старший преподаватель;
E-mail: akopyan.bella@yandex.ru

Поступила в редакцию 04.12.23; одобрена после рецензирования 07.12.23; принята к публикации 08.02.24.

REFERENCES

1. Sun K.K., Xie C.-X., Kuo I.-C. et al. *IEEE Intern. Conf. on Consumer Electronics*, 2022, pp. 557–558.
2. Razavi S.R., Mohammadi M.H.D. *Intern. J. Bioautomation*, 2017, no. 2(21), pp. 165–178.
3. Rakshit M., Panigrahy D., Sahu P. *Sadhana*, 2016, no. 5(41), pp. 469–477.
4. Bouchouareb R., Ferroudji K. *4th International Conference on Pattern Analysis and Intelligent Systems (PAIS)*, 2022, pp. 1–7.
5. Vadillo-Valderrama A., Goya-Esteban R., Caulier-Cisterna R.P. et al. *IEEE Access*, 2022, vol. 10, pp. 129362–129381.
6. Nasim A., Nchekwube D.C., Munir F. et al. *IEEE Access*, 2022, vol. 10, pp. 99050–99065.
7. Pradeepkumar A., Kaul A. *2nd Asian Conference on Innovation in Technology (ASIANCON)*, 2022, pp. 1–6.
8. Wang L.H., Yan Z.H., Yang Y.T. et al. *Sensors*, 2021, no. 21(19), pp. 5222.
9. Sokolova A.A. *Proceedings of Saint Petersburg Electrotechnical University*, 2012, no. 5, pp. 112–118. (in Russ.)
10. Alieva A.M., Golukhova E.Z., Pinchuk T.V. *Archive of internal medicine*, 2013, no. 6, pp. 47–52. (in Russ.)
11. Akopyan B.K., Zharinov O.O. *Obrabotka, peredacha i zashchita informatsii v komp'yuternykh sistemakh* (Processing, Transmission and Protection of Information in Computer Systems), Collection of reports of the Second International Scientific Conference, St. Petersburg, April 11–15, 2022, pp. 15–18. (in Russ.)
12. Hodashinsky I.A., Sarin K.S. *Automation and Remote Control*, 2019, no. 2(80), pp. 324–333.
13. Goncharov Yu.V., Muchnik I.B., Shvartser L.V. *Computational Mathematics and Mathematical Physics*, 2008, no. 7(48), pp. 1243–1260.
14. Glumov N.I., Myasnikov E.V. *Computer optics*, 2007, no. 3, pp. 73–76. (in Russ.)
15. Kartiev S.B., Kureichik V.M. *Software & Systems*, 2016, no. 2(114), pp. 11–15. (in Russ.)
16. Popov N.V., Razmochayeva N.V., Klionsky D.M. *Fifth Conference on Software Engineering and Information Management (SEIM-2020)*, St. Petersburg. 2020, pp. 31–36.
17. Moody G.B., Mark R.G. *IEEE Engineering in Medicine and Biology*, 2001, no. 3(20), pp. 45–50.
18. St. Petersburg INCART 12-lead Arrhythmia Database, 2008, <https://physionet.org/content/incartdb/1.0.0/>.

Data on author

Bella K. Akopyan

— St. Petersburg State University of Aerospace Instrumentation, Department of Applied Informatics; Senior Lecturer; E-mail: akopyan.bella@yandex.ru

Received 04.12.23; approved after reviewing 07.12.23; accepted for publication 08.02.24.

**ИСПОЛЬЗОВАНИЕ ГЛУБОКОГО ОБУЧЕНИЯ
ПРИ ДИАГНОСТИРОВАНИИ ПНЕВМОНИИ ПО РЕНТГЕНОВСКИМ СНИМКАМ****А. С. РАСКОПИНА, В. В. БОЖЕНКО, Т. М. ТАТАРНИКОВА****Санкт-Петербургский государственный университет аэрокосмического приборостроения,**Санкт-Петербург, Россия,***tm-tatarn@yandex.ru*

Аннотация. С развитием методов машинного обучения для распознавания образов открываются новые возможности в области медицинской диагностики. Уровень точности и надежности, достигнутый нейронными сетями, позволяет снизить риск ложных срабатываний и ошибок. Для задачи диагностирования пневмонии по рентгеновским изображениям проведено сравнение различных алгоритмов машинного обучения, таких как метод опорных векторов, k -ближайших соседей, сверточные нейронные сети. Обсуждаются преимущества использования данных методов в медицинской диагностике. Алгоритмы машинного обучения доведены до программной реализации, для каждого из них экспериментальным путем выбраны параметры обучения. Для сравнения методов использовалась стандартная метрика — точность (accuracy), также методы сравнивались по времени обучения. Эксперименты проведены на реальных рентгеновских снимках больных пневмонией пациентов. Результаты экспериментов показали, что глубокие нейронные сети демонстрируют лучшую точность, по сравнению с традиционными методами машинного обучения, что подтверждает эффективность их потенциального использования для диагностики и лечения данного заболевания.

Ключевые слова: рентгеновское изображение, нейронные сети, машинное обучение, диагностика, метод опорных векторов, k -ближайших соседей, сверточные нейронные сети, глубокое обучение

Ссылка для цитирования: Раскопина А. С., Боженко В. В., Татарникова Т. М. Использование глубокого обучения при диагностировании пневмонии по рентгеновским снимкам // Изв. вузов. Приборостроение. 2024. Т. 67, № 4. С. 315—320. DOI: 10.17586/0021-3454-2024-67-4-315-320.

USING DEEP LEARNING IN PNEUMONIA DIAGNOSIS FROM X-RAYS PATTERNS**A. S. Raskopina, V. V. Bozhenko, T. M. Tatarnikova****St. Petersburg State University of Aerospace Instrumentation, St. Petersburg, Russia***tm-tatarn@yandex.ru*

Abstract. With the development of neural networks, new effective solutions in the field of medical diagnosis are opening up. The level of accuracy and reliability achieved by neural networks reduces the risk of false positives and diagnostic errors. In the task of diagnosing pneumonia from X-ray images, various machine learning algorithms such as the support vector machine (SVM), K-nearest neighbors (KNN), convolutional neural networks (CNN) are compared. The advantages of these methods in the task of medical diagnostics are discussed. Machine learning algorithms are brought to software implementation, and for each of them training parameters are selected experimentally. To compare the methods, a standard metric, accuracy, was used, and the methods are also compared by training time. The corresponding experiments are conducted on real data from X-ray images of patients with pneumonia. The experimental results demonstrate better accuracy of deep neural networks compared to traditional machine learning methods, which confirms the effectiveness of their potential use for the diagnosis and treatment of this disease.

Keywords: neural networks, machine learning, diagnostics, support vector method, k-nearest neighbors, convolutional neural networks, deep learning

For citation: Raskopina A. S., Bozhenko V. V., Tatarnikova T. M. Using deep learning in pneumonia diagnosis from x-rays patterns. *Journal of Instrument Engineering*. 2024. Vol. 67, N 4. P. 315—320 (in Russian). DOI: 10.17586/0021-3454-2024-67-4-315-320.

Применение искусственного интеллекта (ИИ) в медицине является одним из направлений, которое поддерживает врачей-специалистов в принятии решений. Безусловно, и раньше

технологии ИИ, например экспертные системы и алгоритмы классификации, применялись в постановке диагноза, но в последние десять лет задача распознавания образов получила наибольшую популярность благодаря развитию моделей глубокого обучения. Эти модели позволяют компьютерам анализировать и интерпретировать медицинские изображения, такие как рентгеновские, КТ- и МРТ-снимки [1—3].

Преимущества от применения технологий распознавания образов очевидны:

- повышение оперативности диагностики — медицинские изображения анализируются в режиме реального времени, что сокращает время ожидания результатов и, соответственно, время начала лечения;

- автоматизированный анализ изображений снижает риск ошибок, которые могут возникнуть при интерпретации снимков человеком;

- точность диагностики повышается, что особенно важно при выявлении редких или с трудом поддающихся анализу заболеваний.

Исследование функций и особенностей работы современных специализированных систем анализа и обработки медицинских изображений показало, что эти системы обладают рядом недостатков. Основным недостатком является то, что большинство систем содержит широкий набор методов анализа и обработки изображений без привязки метода к цели диагностирования [4, 5]. В связи с этим выявлены следующие проблемы: невозможно гарантированно выбрать оптимальный метод или их комбинацию для обработки изображений, а осуществить перебор всех имеющихся в распоряжении исследователя методов для достижения наилучшего результата обработки не всегда возможно.

Поэтому задачу анализа и обработки медицинских изображений можно решать в два этапа: во-первых, накопление размеченной врачами-специалистами обучающей выборки и, во-вторых, выбор модели машинного обучения с требуемыми показателями точности результата и ее построение [6, 7].

Одним из эффективных и приоритетных в медицинской практике способов диагностики является рентгенография: анализ и выявление признаков заболевания по флюорографическим снимкам. Это технически простой и наиболее доступный для пациентов метод предварительной диагностики заболевания, в том числе отслеживания заболевания на ранней стадии.

В настоящей статье решается задача распознавания рентгеновских снимков для диагностирования пневмонии с применением модели глубокого обучения.

Несмотря на все преимущества метода рентгенографии, диагностика заболевания по флюорографическим снимкам является нетривиальной задачей. Сложность задачи заключается, как правило, в низком разрешении изображений и наличии различного рода шумов, таких как засветки, посторонние предметы и т.д. Дополнительные трудности вносит наличие на снимках естественных анатомических структур, например, костей, других перекрывающих органов, которые зачастую скрывают аномалии легочной ткани. Выделение и последующая фильтрация подобного рода структур с учетом разметки, выполненной врачом-рентгенологом, является первым важным этапом решения задачи диагностирования заболевания. Этот этап не является частью настоящей работы — нами использована готовая обучающая выборка из открытого источника, являющаяся площадкой для соревнований по машинному обучению.* Выборка включает 5863 рентгеновских снимка грудной клетки, которые были заранее промаркированы как „здоровые легкие“ и „диагноз пневмония“.

Существует несколько методов классификации, которые можно применять, в том числе для распознавания образов. В настоящей работе выбраны методы опорных векторов, k-ближайших соседей и сверточные нейронные сети.

* <https://www.kaggle.com/datasets/paultimothymooney/chest-xray-pneumonia>.

Метод опорных векторов (SVM) при решении задач классификации обладает определенными преимуществами: меньшее время прогнозирования, а точность классификатора обнаружения цели может быть гарантирована глобальным оптимальным решением. Недостаток метода заключается в линейном росте времени распознавания с увеличением объема данных [8]. Для сравнительного анализа с другими методами распознавания образов метод SVM выбран по нескольким причинам:

- 1) исходные данные — это рентгеновские изображения, которые могут быть представлены высокоразмерными векторами;
- 2) SVM обладает хорошей способностью к обобщению, следовательно, он может давать хорошие результаты на новых данных, не участвовавших в обучении;
- 3) метод достаточно устойчив к шуму в данных.

Метод k -ближайших соседей (KNN) — объекту присваивается класс, который наиболее распространен среди k соседей данного элемента, классы которых уже известны [9]. Причины, по которым этот алгоритм выбран для решения задачи диагностирования пневмонии:

- 1) алгоритм прост в интерпретации;
- 2) обучение проходит без учителя: предварительно модель не обучается, следовательно, сокращается время решения задачи [10].

Известный недостаток заключается в том, что метод не может правильно предсказать ни одно решение, если оно не принадлежит ни к одному из предопределенных классов в наборе обучающих данных.

Сверточные нейронные сети (CNN) представляют собой многослойный стек из нейронов, благодаря чему CNN можно собирать как конструктор, добавляя слой за слоем. Каждый уровень CNN преобразует изображение на своем уровне абстракции [11]. CNN обычно включает сверточные слои, слои объединения и полносвязные слои. Слой свертки CONV является главным слоем CNN. Его назначение — выделить признаки на входном изображении и сформировать карту признаков. Первый сверточный уровень может изучать базовые элементы, такие как ребра, а второй — шаблоны, состоящие из базовых элементов, проанализированных на предыдущем уровне. Это позволяет CNN эффективно изучать все более сложные и абстрактные визуальные концепции. Сверточный слой сопровождается слоями объединения POOL. Объединяющие слои упрощают информацию, собираемую сверточным слоем, и создают сжатую версию информации, содержащейся в них. Полносвязный слой FC объединяет все нейроны предыдущего и последующего слоев и помогает сопоставить данные на входе с меткой класса, как в нейронной сети прямого распространения [12]. В качестве функции активации наиболее часто используются ReLU, Sigmoid, Tanh, LeakyReLU. Таким образом, использование CNN в задаче диагностирования по рентгеновским снимкам обосновано их способностью эффективно выделять признаки из изображений, обучаться на больших объемах данных, а также автоматизировать процесс [13].

В табл. 1 представлена общая структура построенной нейронной сети. В этой сети применяются пять слоев для обработки входных данных: сверточный, пулинговый и три полносвязных.

Таблица 1

Общая структура сверточной нейронной сети

Слой	Выходная форма данных	Число обучаемых параметров
CONV	(None, 148, 148, 32)	896
POOL	(None, 74, 74, 32)	0
FC	(None, 175232)	0
dense_2 (Dense)	(None, 64)	11214912
dense_3 (Dense)	(None, 1)	65

Сверточный слой CONV применяется для выделения различных признаков изображения на входных данных. Размерность выходных данных этого слоя составляет (None, 148, 148, 32), где значение „None“ указывает на то, что модель может принимать пакеты данных

любого размера. После прохождения через этот слой изображение будет иметь размер 148×148 пикселей, а также 32 канала. Каждый из этих 32 каналов представляет собой набор определенных признаков, выделенных изображением в процессе свертки. Общее число параметров на этом слое 896, что отражает количество настраиваемых коэффициентов и смещений в сверточном фильтре, который используется для выделения этих признаков.

Затем данные проходят через пулинговый слой POOL, который снижает размерность данных вдвое. Пулинговый слой не имеет обучаемых параметров, поэтому число параметров на этом слое равно нулю.

Далее данные подаются на полносвязный слой FC, который преобразовывает их в одномерный вектор размером 175 232. Этот слой не имеет обучаемых параметров, поэтому число параметров также равно нулю.

Последние два полносвязных слоя — dense_2 и dense_3 (Dense). Эти слои принимают на вход выходные сигналы всех нейронов предыдущего слоя, умножают их на свои весовые коэффициенты и применяют активационную функцию.

Слой dense_2 использует функцию активации ReLU и имеет 64 нейрона и 11 214 912 параметров, что указывает на количество обучаемых весовых коэффициентов и смещений между нейронами. А слой dense_3 использует функцию активации Sigmoid и имеет 1 нейрон и 65 параметров, включая веса и смещения. Модель после прохождения выходного слоя dense_3 выдает единственное численное значение на основе входных данных.

Точность классификатора оценивалась метрикой ассигасу, показывающей долю правильных решений:

$$\text{accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}},$$

где TP (истинно-положительное решение) — результат предсказания моделью положительного класса объекта совпал с реальной меткой класса; FP (ложноположительное решение) — ошибка 1-го рода, модель ошибочно отнесла объект, который на самом деле относится к отрицательному классу, к положительному; FN (ложноотрицательное решение) — ошибка 2-го рода, модель ошибочно классифицировала отрицательный объект как положительный; TN (истинно-отрицательное решение) — модель верно классифицировала объект как отрицательный.

Все методы классификации доведены до программной реализации. Параметры обучения выбраны экспериментальным путем:

— для обучения SVM использован класс SVC, который осуществляет поддержку мультиклассов по схеме „один против одного“; ядерная функция — радиально-базисная; степень полинома 3;

— при обучении методом KNN лучшие результаты получились для пяти ближайших соседей;

— в модели обучения CNN использованы функция активации ReLU и алгоритм оптимизации Adam, который позволил построить архитектуру нейронной сети, удовлетворяющей максимально возможному значению метрики ассигасу.

Результаты, которые получены в ходе эксперимента, приведены в табл. 2. Из них можно сделать вывод, что с задачей распознавания лучше других методов справилась сверточная нейронная сеть, худшие результаты получены методом опорных векторов. Причиной этому может быть небольшой объем данных для обучения. Также время обучения у сверточной нейронной сети ожидаемо оказалось самым продолжительным.

Таблица 2

Результаты эксперимента		
Модель	Точность (тестовая выборка), о.е.	Время обучения, с
SVM	0,74	489
KNN	0,63	17
CNN	0,89	987

Результаты проведенного исследования показали, что глубокие нейронные сети обеспечивают более высокую точность, чем традиционные методы машинного обучения, в задаче выявления пневмонии на рентгеновских снимках.

СПИСОК ЛИТЕРАТУРЫ

1. Zhang Zh. Introduction to machine learning: K-nearest neighbors // *Annals of Translational Medicine*. 2016. Vol. 4, N 11. P. 218—225. DOI: 10.21037/atm.2016.03.37.
2. Bozhenko V. V. and Tatarnikova T. M. Application of Data Preprocessing in Medical Research // *2023 Wave Electronics and its Application in Information and Telecommunication Systems (WECONF)*. St. Petersburg, 2023. P. 1—4. DOI: 10.1109/WECONF57201.2023.10148004.
3. Razzak M. I., Imran M., Xu G. Big data analytics for preventive medicine // *Neural Computing & Applications*. 2020. Vol. 32. P. 4417—4451.
4. Васильченко В. А., Бурковский В. Л., Данилов А. Д. Алгоритмизация процесса распознавания состояний физиологических объектов на основе специальных рентгеновских изображений // *Компьютерная оптика*. 2019. Т. 43, № 2. С. 296—303.
5. Максимова Е. И., Хаустов П. А. Алгоритм обнаружения образований в легких человека на снимках компьютерного томографа с использованием искусственной нейронной сети // *Фундаментальные исследования*. 2016. № 4–2. С. 290—294.
6. Комков А. А., Мазаев В. П., Рязанова С. В., Самочатов Д. Н., Базаева Е. В. Основные направления развития искусственного интеллекта в медицине // *Научное обозрение. Медицинские науки*. 2020. № 5. С. 33—40.
7. Jaapar R. M. Q. R., Mansor M. A. Convolutional Neural Network Model in Machine Learning Methods and Computer Vision for Image Recognition: A Review // *J. of Applied Sciences Research*. 2018. Vol. 14, N 6. P. 23—27. DOI: 10.22587/jasr.2018.14.6.5.
8. Awad M., Khanna R. Support Vector Machines for Classification // *Efficient Learning Machines*. 2015. P. 39—66. DOI:10.1007/978-1-4302-5990-9_3.
9. Tatarnikova T. M. and Mokretsov N. S. Wireless Sensor Network Clustering Model // *XXVI Intern. Conf. on Soft Computing and Measurements (SCM)*. St. Petersburg, 2023. P. 240—243. DOI: 10.1109/SCM58628.2023.10159119.
10. Paramasivam K., Sindha M. M. R., Balakrishnan S. B. KNN-Based Machine Learning Classifier Used on Deep Learned Spatial Motion Features for Human Action Recognition // *Entropy*. 2023. Vol. 25, N 844. P. 1—15. DOI: 10.3390/e25060844.
11. Alzubaidi L., Zhang J., Humaidi A. J., Al-Dujaili A., Duan Y., Al-Shamma O., Santamaría J., Fadhel M. A., Al-Amidie M., and Farhan L. Review of deep learning: concepts, CNN architectures, challenges, applications, future directions // *J. of Big Data*. 2021. Vol. 8, N 53. P. 1—74. DOI: 10.1186/s40537-021-00444-8.
12. Le Cun Y., Bengio Y., Hinton G. Deep learning // *Nature*. 2015. Vol. 521, N 7553. P. 436—444. DOI:10.1038/nature14539
13. Akcay S., Kundegorski M. E., Willcocks C. G. and Breckon T. P. Using Deep Convolutional Neural Network Architectures for Object Classification and Detection within X-Ray Baggage Security Imagery // *IEEE Transact. on Information Forensics and Security*. 2018. Vol. 13, N 9. P. 2203—2215.

Сведения об авторах

- | | |
|---------------------------------------|---|
| Анастасия Сергеевна Раскопина | — студентка; Санкт-Петербургский государственный университет аэрокосмического приборостроения, кафедра прикладной информатики; E-mail: raskopina.anastasia@yandex.ru |
| Виктория Вячеславовна Боженко | — Санкт-Петербургский государственный университет аэрокосмического приборостроения, кафедра прикладной информатики; старший преподаватель; E-mail: vibozenko@yandex.ru |
| Татьяна Михайловна Татарникова | — д-р техн. наук, профессор; Санкт-Петербургский государственный университет аэрокосмического приборостроения, кафедра прикладной информатики; профессор; E-mail: tm-tatarn@yandex.ru |

Поступила в редакцию 04.12.23; одобрена после рецензирования 12.12.23; принята к публикации 08.02.24.

REFERENCES

1. Zhang Zh. *Annals of Translational Medicine*, 2016, no. 11(4), pp. 218–225, DOI: 10.21037/atm.2016.03.37.
2. Bozhenko V.V. and Tatarnikova T.M. *Wave Electronics and its Application in Information and Telecommunication Systems (WECONF)*, St. Petersburg, 2023, pp. 1–4, DOI: 10.1109/WECONF57201.2023.10148004.
3. Razzak M.I., Imran M., Xu G. *Neural Computing & Applications*, 2020, vol. 32, pp. 4417–4451.
4. Vasilchenko V.A., Burkovsky V.L., Danilov A.D. *Computer optics*, 2019, no. 2(43), pp. 296–303. (in Russ.)
5. Maksimova E.I., Khaustov P.A. *Fundamental research*, 2016, no. 4–2, pp. 290–294. (in Russ.)
6. Komkov A.A., Mazaev V.P., Ryazanova S.V., Samochatov D.N., Bazaeva E.V. *Science review. Medical Sciences*, 2020, no. 5, pp. 33–40, URL: <https://science-medicine.ru/ru/article/view?id=1141>. (in Russ.)
7. Jaapar R.M.Q.R., Mansor M.A. *Journal of Applied Sciences Research*, 2018, no. 6(14), pp. 23–27, DOI: 10.22587/jasr.2018.14.6.5.
8. Awad M., Khanna R. *Efficient Learning Machines*, 2015, pp. 39–66, DOI:10.1007/978-1-4302-5990-9_3.
9. Tatarnikova T.M. and Mokretsov N.S. *XXVI International Conference on Soft Computing and Measurements (SCM)*, St. Petersburg, 2023, pp. 240–243, DOI: 10.1109/SCM58628.2023.10159119.
10. Paramasivam K., Sindha M.M.R., Balakrishnan S.B. *Entropy*, 2023, no. 844(25), pp. 1–15, DOI: 10.3390/e25060844.
11. Alzubaidi L., Zhang J., Humaidi A.J., Al-Dujaili A., Duan Y., Al-Shamma O., Santamaría J., Fadhel M.A., Al-Amidie M., and Farhan L. *Journal of Big Data*, 2021, no. 53(8), pp. 1–74, DOI:10.1186/s40537-021-00444-8.
12. LeCun Y., Bengio Y., Hinton G. *Nature*, 2015, no. 7553(521), pp. 436–444, DOI:10.1038/nature14539.
13. Akcay S., Kundegorski M.E., Willcocks C.G., and Breckon T.P. *IEEE Transactions on Information Forensics and Security*, 2018, no. 9(13), pp. 2203–2215.

Data on authors

- | | |
|-------------------------------|--|
| Anastasia S. Raskopina | — Student; St. Petersburg State University of Aerospace Instrumentation, Department of Applied Informatics; E-mail: raskopina.anastasia@yandex.ru |
| Viktoriya V. Bozhenko | — St. Petersburg State University of Aerospace Instrumentation, Department of Applied Informatics; Senior Lecturer; E-mail: vibozhenko@yandex.ru |
| Tatiana M. Tatarnikova | — Dr. Sci., Professor; St. Petersburg State University of Aerospace Instrumentation, Department of Applied Informatics; Professor; E-mail: tm-tatarn@yandex.ru |

Received 04.12.23; approved after reviewing 12.12.23; accepted for publication 08.02.24.

ИНТЕЛЛЕКТУАЛЬНЫЙ АНАЛИЗ ДАННЫХ В ДИАГНОСТИКЕ АНЕМИИ ПО КЛИНИЧЕСКИМ ПОКАЗАТЕЛЯМ

В. В. БОЖЕНКО^{1*}, Н. Ю. ЧЕРНЫШ², Т. М. ТАТАРНИКОВА¹

¹Санкт-Петербургский государственный университет аэрокосмического приборостроения,

Санкт-Петербург, Россия

*vibozhenko@yandex.ru

²Национальный медицинский исследовательский центр им. В. А. Алмазова,

Санкт-Петербург, Россия

Аннотация. Исследован набор медицинских данных, полученных из информационной системы сетевой лаборатории амбулаторного наблюдения, который содержит показатели анализов пациентов с диагнозом „анемия“. Набор содержит показатели общего анализа крови, ретикулоциты, дополнительные биохимические маркеры обмена железа и воспалительного процесса. Разработана программа, позволяющая автоматизировать процесс анализа исследуемого набора согласно предложенному алгоритму обработки с учетом особенностей медицинских данных. Выполнена предварительная подготовка и очистка данных, проведен статистический и факторный анализ. Анализ выделенных групп данных позволил найти некоторые общие показатели для пациентов с анемическим синдромом. С помощью факторного анализа сокращено число переменных, выделены четыре основных фактора (группы исходных признаков), которые необходимы для описания исследуемых данных. Полученные результаты могут быть использованы для предоставления статистических отчетов медицинской организации. Также исследуемые данные были подготовлены для возможности использования методов машинного обучения и более глубокого анализа с целью выявления наиболее эффективной диагностики анемии на ранних стадиях.

Ключевые слова: анализ медицинских данных, машинное обучение, медицинская статистика, клинические показатели, описательная статистика, факторный анализ

Ссылка для цитирования: Боженко В. В., Черныш Н. Ю., Татарникова Т. М. Интеллектуальный анализ данных в диагностике анемии по клиническим показателям // Изв. вузов. Приборостроение. 2024. Т. 67, № 4. С. 321—329. DOI: 10.17586/0021-3454-2024-67-4-321-329.

DATA MINING IN THE DIAGNOSIS OF ANEMIA BY CLINICAL INDICATORS

V. V. Bozhenko^{1*}, N. Yu. Chernysh², T. M. Tatarnikova¹

¹St. Petersburg State University of Aerospace Instrumentation, St. Petersburg, Russia

vibozhenko@yandex.ru

²V. A. Almazov National Medical Research Center, St. Petersburg, Russia

Abstract. A set of medical data obtained from the information system of a network laboratory for outpatient observation, which contains test indicators of patients diagnosed with anemia, is studied. The set contains indicators of a general blood test, reticulocytes, additional biochemical markers of iron metabolism and the inflammatory process. A program is developed to automate the process of analyzing the test set according to the proposed processing algorithm, taking into account the medical data characteristics. Preliminary preparation and data cleaning are completed, statistical and factor analysis are carried out. Analysis of the selected groups of data makes it possible to find some common indicators for patients with anemic syndrome. Using factor analysis, the number of variables is reduced and four main factors (groups of initial characteristics) necessary to describe the data under study are identified. The results obtained can be used to provide static reports to a medical organization. Also, the studied data are prepared to allow the use of machine learning methods and deeper analysis in order to identify the most effective diagnosis of anemia in the early stages.

Keywords: medical data analysis, machine learning, medical statistics, clinical indicators, descriptive statistics, factor analysis

For citation: Bozhenko V. V., Chernysh N. Yu., Tatarnikova T. M. Data mining in the diagnosis of anemia by clinical indicators. *Journal of Instrument Engineering*. 2024. Vol. 67, N 4. P. 321—329 (in Russian). DOI: 10.17586/0021-3454-2024-67-4-321-329.

Введение. В современном мире ведущие медицинские организации оснащены средствами для сбора и хранения данных в специальных информационных системах. При этом большое количество данных, хранящихся в медицинских базах, требует специальных инструментов для обнаружения полезной информации и выявления важных зависимостей, необходимых для принятия обоснованных решений [1]. Использование искусственного интеллекта в медицине становится возможным благодаря анализу больших объемов данных, одним из источников которых являются лабораторные исследования [2, 3]. Это было бы невозможно без развития технологической базы лабораторной диагностики и применения соответствующих математических инструментов.

В связи со сказанным актуален поиск решений, позволяющих более эффективно использовать базу лабораторных данных для повышения качества медицинской помощи. Как известно, качество лабораторной диагностики подчиняется золотому правилу „правильный тест—правильному пациенту—в правильное время“. Оценка различных клинико-лабораторных факторов облегчает поиск второго неизвестного в данной формуле — группы пациентов, для которых следует назначить то или иное исследование [4—6].

Общий анализ крови (ОАК) является одним из самых распространенных, широкодоступных и чувствительных методов оценки состояния пациента как по совокупности входящих в него показателей, так и по отдельно взятым параметрам. Важнейшей характеристикой является оценка эритроцитарного ростка цельной крови. Анемический синдром существенно осложняет течение и ухудшает прогноз любого заболевания за счет гипоксии. Выявление распространенности анемического синдрома в амбулаторной практике и его характеристики дают дополнительные основания для клинико-лабораторной оценки пациентов.

Определение места и значения каждого отдельного параметра крови или совокупности этих параметров, а также объема исследований, входящих в общий анализ крови, позволит оптимизировать финансовые затраты на лабораторные исследования. Разработка алгоритмов позволит оптимизировать количество тестов, тем самым снижая стоимость обследования пациента.

Современная система здравоохранения вынуждена преодолевать проблемы высокой стоимости лабораторных тестов и невозможности проведения высокотехнологичных тестов во всех лабораториях [5]. Таким образом, поиск дополнительного сочетания маркеров в развернутом общем анализе крови и ассоциация с другими лабораторными и клиническими данными является актуальной задачей.

Использование алгоритмов, объединяющих результаты клинической оценки состояния пациента с результатами лабораторных исследований, позволяет компенсировать слабые стороны каждого метода при его изолированном использовании, а также улучшить аналитические характеристики всего алгоритма.

Цели и задачи исследования. Целью настоящего исследования является разработка программы персонифицированного подхода к диагностике анемии на основе углубленного анализа маркеров гемограммы.

Задачи исследования:

- 1) методами интеллектуального анализа данных провести предварительную обработку больших объемов данных пациентов с диагнозом анемия, наблюдающихся в амбулаторном звене здравоохранения;
- 2) выполнить статистический анализ подготовленных данных;
- 3) подготовить набор данных для дальнейших исследований;
- 4) провести факторный анализ;
- 5) выявить ограничения в использовании данных лабораторных информационных систем в реальной клинической практике.

Для проведения подобных исследований необходимо обрабатывать данные с целью подготовки к математическому моделированию прогностических алгоритмов и применению методов машинного обучения.

Описание исходных данных. При анализе больших объемов данных в клинической и лабораторной практике используются результаты цифровизации и, в частности, возможности лабораторных информационных систем (ЛИС). ЛИС накапливает все данные о пациенте, которые служат возможными идентификационными признаками — от персональных данных до результатов лабораторных исследований, полученных напрямую с анализаторов. Такая совокупность сведений предоставляет пользователю — лечащему врачу, руководителю структурного подразделения, организатору здравоохранения — возможность в любой момент времени получить любую информацию, однако только по тем данным, которые были исходно обозначены как необходимые [6].

В клинко-диагностических лабораториях выполняется большой объем исследований [7, 8], при этом для обработки таких массивов данных с целью автоматизированного извлечения полезной информации целесообразно использовать информационные технологии и методы интеллектуального анализа.

В проводимое исследование по оценке данных большого объема включены несколько проектов для выявления связей между клинко-лабораторными показателями. В общей сложности проанализировано 142 000 результатов лабораторных исследований, часть из которых в последующем включена в обработку в соответствии с критериями: возраст старше 18 лет, наличие анемического синдрома, выполнение общего анализа крови на автоматическом 5diff-анализаторе с включением данных о ретикулоцитах, дополнительных биохимических маркерах обмена железа и воспалительного процесса.

В исследовании использовались данные, полученные из ЛИС сетевой лаборатории амбулаторного наблюдения. Была проведена выгрузка данных по общему анализу крови. В качестве дополнительных данных использованы результаты биохимического исследования для дифференциальной диагностики анемии. Таким образом, одновременно оценивались показатели обмена железа, маркеры воспаления, ретикулоцитарные показатели, необходимые для определения патогенеза анемии с целью выявления прогностически значимых сочетаний.

Описание этапов исследования. При разработке программ для интеллектуального анализа необходимо учитывать особенности медицинских данных. Обработка огромного количества данных сопряжена с большим количеством неточностей, несоответствий, что осложняет получение достоверных результатов. Необходимо грамотно обрабатывать возможные асимметричность, пропуски значений, выбросы, шумы в данных [9, 10].

Процесс обработки медицинских данных обычно включает несколько этапов:

- 1) импорт данных из ЛИС,
- 2) анализ предметной области, постановка целей и задач,
- 3) первичная обработка данных для устранения аномалий,
- 4) статистический анализ, который может включать разделение на группы, для оценки параметров различных групп пациентов,
- 5) применение методов интеллектуального анализа данных, включая факторный анализ, методы машинного обучения для кластеризации пациентов на группы,
- 6) сохранение результатов исследования.

Стоит отметить, что для получения корректных результатов исследования необходима совместная работа медицинского специалиста и аналитика, который использует программные инструменты и информационные технологии для обработки больших массивов данных. Именно такой тандем позволяет добиться наиболее эффективных результатов анализа.

С учетом результатов анализа предметной области была написана программа для автоматической обработки загруженных из системы данных, которая позволяет получить

первичную информацию, выявить аномалии, получить сводную информацию, обнаружить пропуски, провести статистический анализ, и является полезным инструментом извлечения информации из имеющихся данных. С помощью этой программы были проанализированы исходные данные пациентов.

Необходимо подчеркнуть, что программа разрабатывалась на основе выделенных этапов с учетом требований медицинского учреждения к результатам.

Предварительная обработка данных. Важность предварительной обработки очевидна, так как ввод данных в систему может сопровождаться ошибками ввода информации, которые затем повлекут за собой выдвижение неверных гипотез и выводов, что недопустимо в медицинских исследованиях [10].

В ходе предварительного анализа были удалены выбросы — данные, которые отличаются от общего распределения. Для этого использован метод интерквартильных расстояний, где выбросами считаются значения, превышающие 1,5 интерквартильного расстояния [11]. Такое удаление выбросов привело к лучшему соответствию набора данных требованию нормальности, что позволило применить статистический анализ.

На рис. 1 представлено распределение параметра МСН (среднее содержание гемоглобина в эритроците) до (а) и после (б) удаления выбросов (N — количество наблюдений, попадающих в определенные интервалы значений параметра МСН. Данные разбиваются на интервалы, которые соответствуют основаниям столбцов гистограммы).




Рис. 1

Также в ходе предварительного анализа было обнаружено, что в наборе данных полностью заполнены только показатели общего анализа крови, пол, возраст и код пациента. Более специфичные показатели (ретикулоциты, железообмен, ферритин и т.д. — эти показатели могут быть важны для принятия решений врачом) указаны только для 1 % пациентов. Заполнение этих пропусков средним или медианным значением может исказить итоговые результаты. Представляет интерес заполнение таких пропусков с помощью методов машинного обучения, однако классические методы предсказания числовых значений (линейная регрессия, регрессия с помощью дерева решений, случайного леса) не позволяют достигнуть нужной точности, в связи с чем целесообразно применять методы глубокого обучения [12, 13]. В настоящей работе пропущенные значения не заполнялись, а анализ специализированных показателей проводился по тому количеству данных, что имелись в системе.

Статистический анализ. Для анализа количественных данных ОАК были построены диаграммы распределения, чтобы оценить нормальность распределения величин и выделить основные диапазоны значений показателей. Также были построены графики типа boxplot, которые позволяют наглядно описать характеристики величин и являются незаменимым инструментом в описательной статистике [14].

Стоит отметить, что программа позволяет автоматизировать процессы построения графиков, выводить описательные статистики по каждому показателю исходной таблицы, а также выделять некоторые особенности, например, предупреждать об имеющихся выбросах или пропусках в данных, упрощая исследование для конечного пользователя. Однако медицинскому специалисту необходимо оценивать полученные результаты, которые в дальнейшем могут быть применены в ежегодных статистических отчетах.

В ходе работы была построена специальная система фильтров, которая позволяет выделить различные группы пациентов из исходного набора и проанализировать результаты для каждой из этих групп. При обновлении выгрузки и добавлении новых данных с помощью разработанной программы можно легко проводить анализ новых пациентов, разделенных по заранее определенным группам, и выгружать необходимые результаты.

Первоначальная выгрузка из ЛИС сетевой лаборатории составила 142 000 гематологических исследований с результатами, демонстрирующими уровень гемоглобина (Hb) ниже референсного интервала — менее 120 г/л для женщин и менее 130 г/л — для мужчин — в выборке ОАК (рис. 2). Красными линиями показаны нижние границы референсного интервала. В целом по совокупности измерений уровень гемоглобина равен 109,7 г/л (103,0—119,0 г/л).




Рис. 2

На рис. 3 представлено распределение значения среднего объема эритроцитов (MCV) у пациентов с анемией. Референсный интервал (красные линии) — 80—95 фл. На рис. 4 показано распределение значения среднего содержания гемоглобина в эритроцитах у пациентов с анемией в выборке ОАК сетевой лаборатории. Референсный интервал (красные линии) — 27—32 пкг.




Рис. 3




Рис. 4

Из представленных графиков видно, что более половины результатов измерения MCV и MCH находятся в пределах референсных интервалов или смещены в сторону снижения показателей, это в сочетании со снижением гемоглобина может указывать на множество анемических состояний, включая наиболее распространенные железодефицитную анемию (ЖДА) и анемию хронических заболеваний (АХЗ), что отмечается у 75 % пациентов, имеющих MCH ниже 28,5 и MCV ниже 86.

Данные были разделены на две группы: группа, где заполнены все параметры (столбцы таблицы), в которую входят пациенты, сдавшие дополнительные анализы, и группа, где заполнены только общие показатели крови. В ходе проверки выявлено, что для пациентов первой группы средние значения показателей MCH, MCHC, гемоглобина, эритроцитов ниже. С целью проверки был проведен дисперсионный анализ (ANOVA) [14] для сравнения средних значений выборок, уровень значимости был выбран 0,05.

Методы интеллектуального анализа данных. В зависимости от поставленных задач в медицине применяются методы прогнозирования течения болезни или действия препаратов, анализа выживаемости, классификации и выявления диагноза, кластеризации пациентов на различные группы, а также описательные методы для нахождения скрытых зависимостей между показателями и выявления влияния различных факторов на болезнь [15].

Методы преобразования данных включают методы уменьшения размерности для извлечения важных признаков, так как иногда нет необходимости использовать все имеющиеся признаки. Сжатие данных часто необходимо, чтобы достичь более простых моделей и сократить время выполнения алгоритмов машинного обучения, при этом не потеряв точность результата [16, 17].

В работе также был проведен факторный анализ, который позволяет выделить группы взаимосвязанных признаков, которые описывают набор данных. Оценка сравнительной значимости главных компонент производится по их собственным значениям, которые представляют собой дисперсию стандартизированных исходных данных по этой компоненте, т.е. „объясняемую“ ей часть общей дисперсии объектов. Эти значения обычно сопровождаются соответствующими им процентами полной дисперсии и процентами накопленной дисперсии.

На рис. 5, а представлен график „каменистой осыпи“ (scree plot), который позволяет определить число значимых факторов f , необходимых в исследовательском факторном анализе (т.е. количество главных компонент). График представляет распределение собственных значений (собственное значение показывает, какая доля общей изменчивости приходится на компоненту) факторов (E , Eigenvalue) в порядке убывания их величины. На рис. 5, б показан график объясненной дисперсии (синяя кривая — доля дисперсии, зеленая —

суммарная „объясняемая“ дисперсия) — видно, что наибольшая доля p объясненной дисперсии приходится на четыре фактора.




Рис. 5

В результате были выделены четыре группы признаков, которые объединяют некоторые параметры. Таким образом, можно строить модель кластеризации, основанную на факторах, полученных с помощью метода главных компонент, и необязательно использовать все показатели.

Заключение. Таким образом, первичный анализ показывает, что есть ряд ограничений на использование полного набора данных пациентов с диагнозом „анемия“ в связи с пропусками данных. Кроме того, использование методов интеллектуального анализа ограничивает отсутствие:

- 1) информации об основном заболевании или причинах выполнения исследования ОАК;
- 2) сведений о проводимой терапии;
- 3) дополнительных лабораторных исследований, необходимых для идентификации и дифференциальной диагностики причин анемии — не определены ферритин, трансферрин, железо сыворотки, насыщение трансферрина железом, общая железосвязывающая способность сыворотки, ретикулоциты. Наиболее критичным в дифференциальной диагностике анемии хронических заболеваний и железодефицитной анемии являлось отсутствие данных о ферритине.

Возможности автоматизированного гематологического анализа позволяют искать новые клинически значимые маркеры для дифференциальной диагностики анемии. Исследование показало, что традиционный морфологический анализ с проведением ручной микроскопии должен быть расширен расчетными показателями автоматизированной гемограммы. При этом полученные результаты показали, что объем обследований, выполняемых у амбулаторных пациентов, недостаточен для определения характера анемии. Определены ограничения в использовании больших лабораторных данных, накапливающихся в реальной клинической практике.

Следует отметить, что интеллектуальный анализ и машинное обучение активно применяются в медицине, но по большей степени — при работе с изображениями или в размеченных наборах данных для решения задачи классификации с целью постановки диагноза. Наборы данных, позволяющие диагностировать анемию, отсутствуют, поэтому в настоящей работе был подготовлен набор реальных данных для специалистов, которые смогут применять методы интеллектуального анализа и машинного обучения в диагностике анемии.

Разработанная программа позволяет автоматизировать процесс получения статистических данных, помогает принимать решения, осуществлять поиск структурированных данных по запросу, находить скрытые логические и статистические закономерности, а также может использоваться для развернутой оценки изменений, характерных для анемических состояний.

СПИСОК ЛИТЕРАТУРЫ

1. Huang M.-J., Sung H.-S., Hsieh T.-J., Wu M.-C., Chung S.-H. Applying data-mining techniques for discovering association rules // *Soft Computing – A Fusion of Foundations, Methodologies and Applications*. 2020. Vol. 24. P. 8069—8075.
2. Цветкова Л. А., Черченко О. В. Технология больших данных в медицине и здравоохранении России и мира // *Врач и информационные технологии*. 2016. № 3. С. 60—73.
3. Карнаухов Н. С., Ильюхин Р. Г. Возможности технологий „Big Data“ в медицине // *Врач и информационные технологии*. 2019. № 1. С. 59—63.
4. Explore the Top 10 Cardiac Diagnosis Trends in 2023 [Электронный ресурс]: <<https://www.startus-insights.com/innovators-guide/cardiac-diagnosis-trends/>>. (дата обращения 15.01.2024)
5. Chang A., Cowling K. Past, present, and future of global health financing: A review of development assistance, government, out-of-pocket, and other private spending on health for 195 countries, 1995-2050 // *Lancet*. 2019. Vol. 393, N 10187. P. 2233—2260.
6. Овчинникова М. А., Жиленкова Ю. И., Черныш Н. Ю. Применение big data в лабораторной медицине // *Российский журнал персонализированной медицины*. 2023. Т. 3, № 4. С. 77—87.
7. Wang L. Big data analytics in medical engineering and healthcare: methods, advances and challenges // *J. of Medical Engineering & Technology*. 2020. Vol. 44, N 6. P. 267—283.
8. Razzak M. I., Imran M., Xu G. Big data analytics for preventive medicine // *Neural Computing & Applications*. 2020. Vol. 32. P. 4417—4451.
9. Bozhenko V. V. Data preprocessing in machine learning // *Bulletin of the UNESCO department „Distance education in engineering“ of the SUAI: Collection of the papers*. St. Petersburg, 2023. P. 52—55.
10. Bozhenko V. V., Tatarnikova T. M. Application of Data Preprocessing in Medical Research // *Wave Electronics and its Application in Information and Telecommunication Systems (WECONF)*. St. Petersburg, 2023. P. 1—4.
11. Баврина А. П. Современные правила использования методов описательной статистики в медико-биологических исследованиях // *Медицинский альманах*. 2020. С. 95—104.
12. Makridakis S., Spiliotis E., Assimakopoulos V. Statistical and Machine Learning forecasting methods: Concerns and ways forward // *PloS one*. 2018. Vol. 13. P. 1—20.
13. Попова И. А. Исследование алгоритмов машинного обучения для предварительной обработки данных в задачах регрессии // *Искусственный интеллект в автоматизированных системах управления и обработки данных: Сб. ст. Всерос. научн. конф. Т. 1. М., 2022. С. 237—242.*
14. Гудинова Ж. В., Демакова Л. В. Технологии статистического анализа медицинских данных: первичный анализ данных, сравнение групп // *Фундаментальная и клиническая медицина*. 2023. Т. 8, № 1. С. 119—131.
15. Комков А. А., Мазаев В. П., Рязанова С. В., Самочатов Д. Н., Базаева Е. В. Основные направления развития искусственного интеллекта в медицине // *Научное обозрение. Медицинские науки*. 2020. № 5. С. 33—40.
16. Taherdoost H., Sahibuddin S., Jalaliyoon N. Exploratory Factor Analysis; Concepts and Theory // *Advances in applied and pure mathematics*. 2022. Vol. 27. P. 375—382.
17. Покидышева Л. И., Мадаминова М. О., Ладнюк В. В. Исследование и разработка алгоритмов и программных средств сокращения размерности многомерных данных // *Международ. науч.-исслед. журн*. 2017. № 5–3(59). С. 94—97.

Сведения об авторах

Виктория Вячеславовна Боженко

— Санкт-Петербургский государственный университет аэрокосмического приборостроения, кафедра прикладной информатики; старший преподаватель; E-mail: vibozhenko@yandex.ru

Наталья Юрьевна Черныш

— канд. мед. наук; Национальный медицинский исследовательский центр им. В. А. Алмазова, кафедра лабораторной медицины с клиникой; доцент; E-mail: nycher@mail.ru

Татьяна Михайловна Татарникова

— д-р техн. наук, профессор; Санкт-Петербургский государственный университет аэрокосмического приборостроения, кафедра прикладной информатики; профессор; E-mail: tm-tatarn@yandex.ru

Поступила в редакцию 04.12.23; одобрена после рецензирования 07.12.23; принята к публикации 08.02.24.

REFERENCES

1. Huang M.-J., Sung H.-S., Hsieh T.-J., Wu M.-C., Chung S.-H. *Soft Computing - A Fusion of Foundations, Methodologies and Applications*, 2020, vol. 24, pp. 8069–8075.
2. Tsvetkova L.A., Cherchenko O.V. *Medical Doctor and IT*, 2016, no. 3, pp. 60–73. (in Russ.)
3. Karnaukhov N.S., Ilyukhin R.G. *Medical Doctor and IT*, 2019, no. 1, pp. 59–63. (in Russ.)
4. *Explore the Top 10 Cardiac Diagnosis Trends in 2023*, <https://www.startus-insights.com/innovators-guide/cardiac-diagnosis-trends/>.
5. Chang A., Cowling K. *Lancet*, 2019, no. 10187(393), pp. 2233–2260.
6. Ovchinnikova M.A., Zhilenkova Yu.I., Chernysh N.Yu. *Russian Journal for Personalized Medicine*, 2023, no. 4(3), pp. 77–87. (in Russ.)
7. Wang L. *Journal of Medical Engineering & Technology*, 2020, no. 6(44), pp. 267–283.
8. Razzak M.I., Imran M., Xu G. *Neural Computing & Applications*, 2020, vol. 32, pp. 4417–4451.
9. Bozhenko V.V. *Bulletin of the UNESCO department „Distance education in engineering“ of the SUAI*, Collection of the papers. St. Petersburg, 2023, pp. 52–55.
10. Bozhenko V.V., Tatarnikova T.M. *Wave Electronics and its Application in Information and Telecommunication Systems (WECONF)*, St. Petersburg, 2023, pp. 1–4.
11. Bavrina A.P. *Meditsinskiy al'manakh*, 2020, pp. 95–104. (in Russ.)
12. Makridakis S., Spiliotis E., Assimakopoulos V. *PloS one*, 2018, vol. 13, pp. 1–20.
13. Popova I.A. *Iskusstvennyy intellekt v avtomatizirovannykh sistemakh upravleniya i obrabotki dannykh* (Artificial Intelligence in Management, Control, and Data Processing Systems), Collection of articles of the All-Russian Scientific Conference, vol. 1, Moscow, 2022, pp. 237–242. (in Russ.)
14. Gudina Zh.V., Demakova L.V. *Fundamental and Clinical Medicine*, 2023, no. 1(8), pp. 119–131. (in Russ.)
15. Komkov A.A., Mazaev V.P., Ryazanova S.V., Samochatov D.N., Bazaeva E.V. *Science review. Medical Sciences*, 2020, no. 5, pp. 33–40. (in Russ.)
16. Taherdoost H., Sahibuddin S., Jalaliyoon N. *Advances in applied and pure mathematics*, 2022, vol. 27, pp. 375–382.
17. Pokidysheva L.I., Madaminova M.O., Ladnyuk V.V. *International Research Journal*, 2017, no. 5-3(59), pp. 94–97. (in Russ.)

Data on authors**Viktoriya V. Bozhenko**

— St. Petersburg State University of Aerospace Instrumentation, Department of Applied Informatics; Senior Lecturer; E-mail: vibozenko@yandex.ru

Natalia Yu. Chernysh

— PhD; V. A. Almazov National Medical Research Center, Department of Laboratory Medicine with Clinic; Associate Professor; E-mail: nycher@mail.ru

Tatiana M. Tatarnikova

— Dr. Sci., Professor; St. Petersburg State University of Aerospace Instrumentation, Department of Applied Informatics; Professor; E-mail: tm-tatarn@yandex.ru

Received 04.12.23; approved after reviewing 08.12.23; accepted for publication 08.02.24.

МЕТОДЫ ОПТИМИЗАЦИИ МОДЕЛЕЙ НЕЙРОННЫХ СЕТЕЙ

Н. С. МОКРЕЦОВ*, Е. Д. АРХИПЦЕВ

*Санкт-Петербургский государственный электротехнический университет
„ЛЭТИ“ им. В. И. Ульянова (Ленина), Санкт-Петербург, Россия
nikitamokrecov6374@gmail.com

Аннотация. Рассмотрены методы построения ускорителей глубокого обучения. Показано, что традиционные подходы к обеспечению отказоустойчивости ускорителей глубокого обучения основаны на избыточных вычислениях, что приводит к значительным накладным расходам, включая время обучения, энергопотребление и размеры интегральных схем. Рассмотрен метод, основанный на учете различий в уязвимости отдельных нейронов и битов каждого нейрона, частично решающий проблему избыточности вычислений. Метод позволяет избирательно защищать компоненты модели на уровне архитектуры и схемы, что снижает накладные расходы без ущерба для надежности модели. Показано, что квантование модели ускорителя глубокого обучения позволяет представлять данные меньшим числом битов, что снижает требования к аппаратным ресурсам.

Ключевые слова: глубокое обучение, ускоритель глубокого обучения, отказоустойчивость, межуровневая оптимизация, квантование модели обучения

Ссылка для цитирования: Мокрецов Н. С., Архипцев Е. Д. Методы оптимизации моделей нейронных сетей // Изв. вузов. Приборостроение. 2024. Т. 67, № 4. С. 330—337. DOI: 10.17586/0021-3454-2024-67-4-330-337.

METHODS FOR OPTIMIZING NEURAL NETWORK MODELS

N. S. Mokretsov*, E. D. Arkhipsev

*St. Petersburg Electrotechnical University, St. Petersburg, Russia
nikitamokrecov6374@gmail.com

Abstract. Methods for building optimized deep learning accelerators are discussed. Traditional approaches to fault-tolerant deep learning accelerators are shown to rely on redundant computation, which results in significant overheads including training time, power consumption, and integrated circuit size. A method is proposed that considers differences in the vulnerability of individual neurons and the bits of each neuron, which partially solves the problem of computational redundancy. The method allows you to selectively protect model components at the architectural and circuit levels, which reduces overhead without compromising the reliability of the model. It is shown that quantization of the deep learning accelerator model allows data to be represented in fewer bits, which reduces hardware resource requirements.

Keywords: deep learning, deep learning accelerator, fault tolerance, cross-layer optimization, learning model quantization

For citation: Mokretsov N. S., Arkhipsev E. D. Methods for optimizing neural network models. Journal of Instrument Engineering. 2024. Vol. 67, N 4. P. 330—337 (in Russian). DOI: 10.17586/0021-3454-2024-67-4-330-337.

Введение. Применение глубокого обучения выходит за рамки традиционных областей, таких как компьютерное зрение и обработка естественного языка. Современные приложения глубокого обучения применяются в сферах, в которых безопасность является критически важным параметром, например, автономное вождение, аэрокосмическая промышленность и робототехника [1]. Очевидно, что к таким приложениям предъявляются высокие требования по надежности в дополнение к требованиям по точности результата и скорости его получения.

Поскольку модели глубокого обучения включают в себя множество нелинейных функций, которые смягчают влияние ошибок на результаты, точность в получении результата ложится на саму модель глубокого обучения.

Требуемая скорость обучения достигается использованием механизма ускорения (ускорителя) глубокого обучения. Ускоритель реализуется как процессор в виде электронной схемы, специализированный под алгоритмы глубокого обучения, который может встраиваться от мобильных устройств до серверов облачных вычислений.

Модели глубокого обучения включают в себя множество нелинейных функций, что приводит к отсеиванию большего количества ошибок в промежуточных вычислениях и смягчению влияния случайных сбоев на результат вывода модели. Эти особенности глубокого обучения показывают, что такой подход более отказоустойчив, по сравнению с вычислениями общего назначения. Многие работы по созданию надежных ускорителей глубокого обучения используют это естественное свойство отказоустойчивости, добиваясь совместной оптимизации точности, надежности и производительности.

Основной целью использования приложения глубокого обучения является обеспечение надежности. Например, бортовой модуль глубокого обучения транспортного средства должен соответствовать стандарту надежности самого средства [2, 3]. Таким образом, отказоустойчивая архитектура ускорителя является основой для обеспечения надежности и самой модели глубокого обучения, что обуславливает актуальность темы исследования.

Обзор методов проектирования отказоустойчивого ускорителя глубокого обучения. Для повышения надежности ускорителей глубокого обучения предлагаются различные методы отказоустойчивого проектирования на разных уровнях абстракции, таких как схема, архитектура и алгоритм.

На уровне схемы процессора ускорителя могут использоваться традиционные методы отказоустойчивого кодирования, применяющие, в частности, код коррекции ошибок для защиты встроенных кэш-памятей. С одной стороны, это решает проблему потери точности, вызванной сбоями, с другой — большой объем избыточных вычислений негативно влияет на скорость обработки, размеры микросхемы ускорителя и энергопотребление.

Для снижения стоимости избыточных вычислений в работе [4] предложена идея предоставления приоритетной защиты битам старшего порядка вычислительных блоков процессора ускорителя, при этом младшие биты игнорируются. В статье [5] предлагается использовать логику стохастических вычислений (работающую с вероятностными сигналами) взамен традиционной двоичной вычислительной логики с целью повышения энергоэффективности вычислений. В работе [6] предложено применять схему Razor — интеллектуального обработчика программного кода динамических веб-страниц — для обнаружения временных сбоев, вызванных перепадами напряжения. В статье [7] добавление избыточных соединений к ускорителю нейронных сетей Хопфилда и использование логики голосования для исправления ошибок помогает оптимизировать модель обучения.

Для оптимизации модели глубокого обучения на уровне ее архитектуры также предложено несколько решений. Например, в [8] представлена гетерогенная вычислительная архитектура для преодоления проблемы произвольных сбоев в вычислительном массиве ускорителя за счет использования вычислительного массива скалярного произведения, отличного от двумерного пульсирующего массива, для достижения повторного вычисления задач на любом вычислительном блоке. В работе [9] предлагается выделять в ускорителе глубокого обучения высоконадежные и обычные вычислительные области, которые используются для обработки чувствительных и не чувствительных к сбоям вычислительных задач соответственно. Распределение чувствительных и не чувствительных к сбоям вычислительных задач может меняться в зависимости от модели или входных данных. В статье [10] описываются типы архитектуры, в которых для оптимизации добавляется интегрированный обучающий модуль поверх ускорителя, который позволяет проводить параллельные вычисления нескольких меньших моделей глубокого обучения, чтобы исключить аппаратные сбои и повысить надежность вывода. В работе [11] описывается решение по оптимизации модели нейронной сети с помощью до-

бавления в вычислительный массив глубокого обучения блоков проверки четности для исправления ошибок в режиме реального времени.

На уровне алгоритма устойчивость моделей глубокого обучения к аппаратным сбоям повышается за счет избыточности учитываемых параметров, а точность — за счет изменения параметров модели или ее архитектуры [12, 13]. Аппаратная схема ускорителя при таком подходе остается неизменной. Некоторые алгоритмы повышают отказоустойчивость модели глубокого обучения за счет применения эквивалентных вычислительных методов, вводя новые функции активации или числовые ограничения либо используя механизмы контрольной суммы для исправления ошибок [14, 15].

Как показывает анализ источников, большинство отказоустойчивых методов глубокого обучения используются в основном на одном уровне схемы, архитектуры или алгоритма. Различные методы имеют преимущества и недостатки, также существуют различные ограничения в сценариях их использования. Несмотря на то что возможно использовать некоторые комбинации различных уровней архитектуры для повышения точности результатов или снижения затрат на отказоустойчивость, по-прежнему не хватает методов межуровневого проектирования отказоустойчивых ускорителей глубокого обучения.

Межуровневая оптимизация. Как показывает анализ источников, большинство отказоустойчивых методов глубокого обучения используются в основном на одном уровне схемы, архитектуры или алгоритма. Различные методы имеют преимущества и недостатки, также существуют различные ограничения в сценариях их использования. Несмотря на то что существуют некоторые комбинации различных уровней архитектуры для повышения точности результатов или снижения затрат на отказоустойчивость, по-прежнему не хватает методов межуровневого проектирования отказоустойчивых ускорителей глубокого обучения.

Общая архитектура многоуровневой оптимизации отказоустойчивого ускорителя глубокого обучения показана на рис. 1.




Рис. 1

В вычислительных задачах глубокого обучения целесообразно выделять важные и обычные вычисления, дополнительно разделять данные о нейронах на важные и обычные битовые данные. Такое разделение позволяет обеспечить избирательную защиту.

На уровне схемы предлагается резервирование с побитовой защитой — защищаются только важные логические разряды вычислительного блока. Для двух типов вычислительных массивов применяются различные методы защиты от избыточности, что еще больше снижает затраты на резервирование.

Таким образом, алгоритм построения межуровневой оптимизации имеет следующий вид.

1. Пользователь определяет цели модели обучения и ограничения, такие как производительность, надежность и доступные объемы вычислительных ресурсов. Пусть надежность обычно определяется точностью модели обучения, затраты на вычислительные ресурсы отражают объемы дополнительной вычислительной мощности (CPU, GPU, TPU и т.д.), необходимой для введения отказоустойчивости в модели, в сравнении со стандартной моделью нейронной сети.

2. Фреймворк анализирует чувствительность различных нейронов к сбоям на уровне алгоритма и использует это в качестве основы для разделения в глубоком обучении на важные вычисления и вычисления общего характера. Поскольку важные вычисления более чувствительны к сбоям и приводят к большей потере точности модели обучения, то для них требуются более надежные отказоустойчивые конструкции.

Для автоматического разделения на важные вычисления и вычисления общего характера в глубоком обучении можно воспользоваться расширением архитектуры HyCA [2] или настраиваемой архитектурой отказоустойчивого ускорителя глубокого обучения FlexHyCA, представленной в работе [16] и изображенной на рис. 2.




Рис. 2

FlexHyCA состоит из плоской сети вычислительных элементов для обработки обычных вычислений и блока обработки скалярного произведения (БЛОС) небольшого количества важных вычислений, на которые распространяются требования высокой надежности. Информация о расположении важных нейронов попадает в сеть вычислительных элементов для сегментации элементов по важности вычисляемого в нем нейрона. За счет этого БЛОС может

повторно использовать данные, загруженные в кэш сети вычислительных элементов, либо напрямую считывать необходимые данные из оперативной памяти (DRAM).

С учетом разницы в чувствительности к сбоям между важными и обычными битами нейронов в моделях глубокого обучения используются схемы селективной защиты битов на вычислительных блоках FlexHyCA. Только важные биты обычных нейронов и непосредственно связанные логические схемы важных битов важных нейронов избыточно защищаются, чтобы сократить дополнительные вычислительные ресурсы отказоустойчивого проектирования.

3. Квантование модели, которое позволяет использовать меньшую разрядность данных для вычислений и тем самым делать обработку данных в глубоком обучении более энергоэффективной. Как правило, процессор, на котором строится ускоритель глубокого обучения, поддерживает квантование с фиксированной точкой базовых вычислительных единиц, таких как блоки умножения-суммирования.

Для демонстрации результатов применения описанного выше подхода в работе [16] использовалось ПО, имитирующее случайные сбои (soft error), обозначенные как частота битовых ошибок (ЧБО). ЧБО устанавливает вероятность случайных сбоев в каждом блоке памяти, содержащем кэш. Для двух экспериментов (I — ЧБО = 0,0001; II — ЧБО = 0,0002) были установлены два различных ограничения по надежности/точности. По сравнению с обычной моделью глубокого обучения (с такой же функцией и ограничениями, но без требования оптимизации), потеря точности составляет менее 3 % в эксперименте I и менее 5 % — в II, при этом потеря производительности и пропускной способности составляет менее 10 %. Стоимость дополнительных вычислительных ресурсов сведена к минимуму при условии соблюдения ограничений по точности, производительности и пропускной способности.

В экспериментах использовались ImageNet в качестве датасета, а VGG 16 и ResNet50 — в качестве типичных моделей глубокого обучения для сравнения характеристик моделей. Обе модели были модифицированы с использованием 8-разрядного целочисленного квантования, в результате чего точность квантованной модели составила 72,95 и 75,96 % соответственно.

С целью проверки этого алгоритма межуровневого оптимизированного проектирования для ускорителя глубокого обучения с точки зрения аппаратной надежности (точности), накладных расходов на аппаратные ресурсы и производительности, сравниваются базовая конструкция ускорителя — Base, конструкция селективного тройного модульного резервирования (TMR — triple modular redundancy) на уровне схемы (CRT — circuit) с различной длиной битового слова: TMR-CRT1, TMR-CRT2, TMR-CRT3; схема селективного тройного модульного резервирования на уровне архитектуры (ARCH — architecture): TMR-ARCH; схема селективного тройного модульного резервирования на уровне алгоритма (ALG — algorithm): TMR-ALG; и схема межуровневого (CL — cross-layer) резервирования — TMR-CL.

Суть эксперимента заключалась в эмулировании случайных сбоев (fault injection) с упомянутыми выше частотами. Base — исходная модель, в которой не используется какая-либо защита от ошибок. Модели TMR соответствуют применению различных схем защиты с результирующим значением точности модели. На рис. 3 представлены изменения в точности моделей T вследствие применения межуровневой оптимизации (a — точность модели VGG 16 после оптимизации ускорителя глубокого обучения для эксперимента I; b — точность модели ResNet50 после оптимизации ускорителя глубокого обучения для эксперимента I; c — точность модели VGG 16 после оптимизации ускорителя глубокого обучения для эксперимента II; d — точность модели ResNet50 после оптимизации ускорителя глубокого обучения для эксперимента II).




Рис. 3

В целом, различные отказоустойчивые стратегии могут соответствовать требованиям обеспечения точности. Однако относительная гибкость таких конструкций, как TMR-ARCH, TMR-ALG и TMR-CL, позволяет находить настройки, которые точно соответствуют требованиям пользователя. Напротив, степень детализации TMR-CRT относительно высока, а различия в точности значительны. TMR-CRT1 не соответствует требованиям по точности в соответствии со сценарием II, в то время как TMR-CRT2 и TMR-CRT3 превысили требования пользователя к точности.

Выводы. В обеспечении надежной работы критически важных приложений, основанных на моделях нейронных сетей, отказоустойчивое проектирование ускорителя глубокого обуче-

ния является определяющим фактором. Ускорители глубокого обучения способствуют повышению производительности и энергоэффективности обучения глубоких нейронных сетей.

Основные подходы к оптимизации ускорителя глубокого обучения специализируются только на одном из уровней абстракции моделей и зачастую основаны на избыточных вычислениях, что приводит к значительным затратам вычислительных ресурсов. Для обхода этих ограничений предлагается рассмотреть различия в уязвимости схемы к сбоям с точки зрения нейронных вычислений и разрядностей отдельного нейрона сети, и, основываясь на этих различиях, выбрать соответствующие методы выборочной защиты алгоритма, архитектуры и схемы модели глубокого обучения.

Эксперименты показывают, что межуровневая оптимизация ускорителя глубокого обучения позволяет настроиться под требования пользователя по точности модели обучения с учетом ограничений на имеющиеся ресурсы по энергоэффективности и производительности.

СПИСОК ЛИТЕРАТУРЫ

1. Chen Y., Luo T., Liu S., Zhang S., He L., Wang J., Li L., Chen T., Xu Z., Sun N. Dadiannao: A machine-learning supercomputer // Annual IEEE/ACM Intern. Symp. on Microarchitecture. 2014. Vol. 47. P. 609—622.
2. Liu C., Chu C., Xu D., Wang Y., Wang Q., Li H., Li X., Cheng K., Hуca T. A hybrid computing architecture for fault-tolerant deep learning // IEEE Transact. on Computer-Aided Design of Integrated Circuits and Systems. 2021. Vol. 41, N 10. P. 3400—3413.
3. Dixit A., Wood A. The impact of new technology on soft error rates // 2011 Intern. Reliability Physics Symposium. IEEE. 2011. P. 5B—4.
4. Hoang L. H., Hanif M. A., Shafique M. Ft-clipact: Resilience analysis of deep neural networks and improving their fault tolerance using clipped activation // Design, Automation & Test in Europe Conference & Exhibition (DATE). IEEE. 2020. P. 1241—1246.
5. Ardakani A., Gross W. J. Fault-tolerance of binarized and stochastic computing-based neural networks // IEEE Workshop on Signal Processing Systems (SiPS). IEEE. 2021. P. 52—57.
6. Mittal S. A survey on modeling and improving reliability of dnn algorithms and accelerators // J. of Systems Architecture. 2020. Vol. 104. P. 101.
7. Chen Z., Li G., Pattabiraman K. A low-cost fault corrector for deep neural networks through range restriction // Annual IEEE/IFIP Intern. Conf. on Dependable Systems and Networks (DSN). IEEE. 2021. Vol. 51. P. 1—13.
8. Chen Y. H., Emer J., Sze V. Eyeriss: A spatial architecture for energy-efficient dataflow for convolutional neural networks // ACM SIGARCH computer architecture news. 2016. Vol. 44, N 3. P. 367—379.
9. Libano F., Wilson B., Anderson J., Wirthlin M. J., Cazzaniga C., Frost C., Rech P. Selective hardening for neural networks in fpgas // IEEE Transact. on Nuclear Science. 2018. Vol. 66, N 1. P. 216—222.
10. Mahdiani H. R., Fakhraie S. M., Lucas C. Relaxed fault-tolerant hardware implementation of neural networks in the presence of multiple transient errors // IEEE Transact. on Neural Networks and Learning Systems. 2012. Vol. 23, N 8. P. 1215—1228.
11. Schorn C., Guntoro A., Ascheid G. Accurate neuron resilience prediction for a flexible reliability management in neural network accelerators // Design, Automation & Test in Europe Conference & Exhibition (DATE). IEEE. 2018. P. 979—984.
12. Мокрецов Н. С., Татарникова Т. М. Самоорганизующиеся нейронные клеточные автоматы для обучения с подкреплением и эволюционного развития // Изв. СПбГЭТУ ЛЭТИ. 2023. Т. 16, № 7. С. 68—75.
13. Sovetov B. Y., Tatarnikova T. M., Cehanovsky V. V. Detection system for threats of the presence of hazardous substance in the environment // Proc. of 22nd Intern. Conf. on Soft Computing and Measurements, SCM 2019. 2019. P. 121—124.
14. Wang H., Feng R., Han Z. F., Leung C. S. Admm-based algorithm for training fault tolerant rbf networks and selecting centers // IEEE Transact. on Neural Networks and Learning Systems. 2017. Vol. 29, N 8. P. 3870—3878.

15. Bertoa T. G., Gambardella G., Fraser N. J., Blott M., McAllister J. Fault tolerant neural network accelerators with selective tnr // *IEEE Design & Test*. 2022. <https://doi.org/10.1109/MDAT.2022.3174181>.
16. Rabe M., Milz S., Mader P. Development methodologies for safety critical machine learning applications in the automotive domain: A survey // *Proc. of the IEEE/CVF Conf. on Computer Vision and Pattern Recognition*. 2021. P. 129—141.

Сведения об авторах**Никита Сергеевич Мокрецов**

— аспирант; Санкт-Петербургский государственный электротехнический университет „ЛЭТИ“ им. В.И. Ульянова (Ленина), кафедра информационных систем; E-mail: nikitamokrecov6374@gmail.com

Евгений Дмитриевич Архипцев

— аспирант; Санкт-Петербургский государственный электротехнический университет „ЛЭТИ“ им. В.И. Ульянова (Ленина), кафедра информационных систем; E-mail: lokargenia@gmail.com

Поступила в редакцию 04.12.23; одобрена после рецензирования 08.12.23; принята к публикации 08.02.24.

REFERENCES

1. Chen Y., Luo T., Liu S., Zhang S., He L., Wang J., Li L., Chen T., Xu Z., Sun N. *Annual IEEE/ACM Intern. Symp. on Microarchitecture*, 2014, vol. 47, pp. 609–622.
2. Liu C., Chu C., Xu D., Wang Y., Wang Q., Li H., Li X., Cheng K., Hysa T. *IEEE Transact. on Computer-Aided Design of Integrated Circuits and Systems*, 2021, no. 10(41), pp. 3400–3413.
3. Dixit A., Wood A. *2011 Intern. Reliability Physics Symp.*, IEEE, 2011, pp. 5B–4.
4. Hoang L.H., Hanif M.A., Shafique M. *Design, Automation & Test in Europe Conf. & Exhibition (DATE)*, IEEE, 2020, pp. 1241–1246.
5. Ardakani A., Gross W.J. *IEEE Workshop on Signal Processing Systems (SiPS)*, IEEE, 2021, pp. 52–57.
6. Mittal S. *Journal of Systems Architecture*, 2020, vol. 104, pp. 101.
7. Chen Z., Li G., Pattabiraman K. *Annual IEEE/IFIP Intern. Conf. on Dependable Systems and Networks (DSN)*, IEEE, 2021, vol. 51, pp. 1–13.
8. Chen Y. H., Emer J., Sze V. *ACM SIGARCH computer architecture news*, 2016, no. 3(44), pp. 367–379.
9. Libano F., Wilson B., Anderson J., Wirthlin M. J., Cazzaniga C., Frost C., Rech P. *IEEE Transact. on Nuclear Science*, 2018, no. 1(66), pp. 216–222.
10. Mahdiani H. R., Fakhraie S. M., Lucas C. *IEEE Transact. on Neural Networks and Learning Systems*, 2012, no. 8(23), pp. 1215–1228.
11. Schorn C., Guntoro A., Ascheid G. *Design, Automation & Test in Europe Conference & Exhibition (DATE)*, IEEE, 2018, pp. 979–984.
12. Mokretsov N.S., Tatarnikova T.M. *Proc. of Saint Petersburg Electrotechnical University*, 2023, no. 7(16), pp. 68–75. (in Russ.)
13. Sovetov B.Y., Tatarnikova T.M., Cehanovsky V.V. *Proc. of 22nd Intern. Conf. on Soft Computing and Measurements, SCM 2019*, 2019, pp. 121–124.
14. Wang H., Feng R., Han Z.F., Leung C.S. *IEEE Transact. on Neural Networks and Learning Systems*, 2017, no. 8(29), pp. 3870–3878.
15. Bertoa T.G., Gambardella G., Fraser N. J., Blott M., McAllister J. *IEEE Design & Test.*, 2022, <https://doi.org/10.1109/MDAT.2022.3174181>.
16. Rabe M., Milz S., Mader P. *Proc. of the IEEE/CVF Conf. on Computer Vision and Pattern Recognition*, 2021, pp. 129–141.

Data on authors**Nikita S. Mokretsov**

— Post-Graduate Student; St. Petersburg Electrotechnical University, Department of Information Systems; E-mail: nikitamokrecov6374@gmail.com

Evgeny D. Arkhiptsev

— Post-Graduate Student; St. Petersburg Electrotechnical University, Department of Information Systems; E-mail: lokargenia@gmail.com

Received 04.12.23; approved after reviewing 08.12.23; accepted for publication 08.02.24.

ИНФОРМАТИКА И ИНФОРМАЦИОННЫЕ ПРОЦЕССЫ

INFORMATICS AND INFORMATION PROCESSES

УДК 004.421.5
DOI: 10.17586/0021-3454-2024-67-4-338-344

ГЕНЕРАЦИЯ СЛУЧАЙНЫХ ЧИСЕЛ ДЛЯ ИНТЕРАКТИВНЫХ ПРИЛОЖЕНИЙ С ИСПОЛЬЗОВАНИЕМ ВНЕШНИХ ДАТЧИКОВ

Д. А. БУЛГАКОВ

*Санкт-Петербургский государственный университет аэрокосмического приборостроения,
Санкт-Петербург, Россия
dmbulg@gmail.com*

Аннотация. Представлен метод получения псевдослучайных чисел для их дальнейшего использования при разработке интерактивных приложений на движке Unity со сбором информации от датчиков давления и цвета, подключаемых к микроконтроллеру Arduino. Метод предполагает использование результатов периодических измерений давления, температуры, освещенности и цветов по каналам RGB в помещении, их побитовый сдвиг на случайное число разрядов, получение „зерна“ генератора псевдослучайных чисел путем взятия остатка от деления после сравнения числа с текущим UNIX-временем. Разработано приложение, реализующее предложенный метод генерации псевдослучайных чисел. Показаны результаты тестирования генератора псевдослучайных чисел. Проведена проверка равномерности распределения и оценка коэффициента корреляции на выборке случайных чисел.

Ключевые слова: случайные числа, генератор псевдослучайных чисел, интерактивное приложение, датчик давления, датчик цвета, Arduino, Unity

Ссылка для цитирования: Булгаков Д. А. Генерация случайных чисел для интерактивных приложений с использованием внешних датчиков // Изв. вузов. Приборостроение. 2024. Т. 67, № 4. С. 338—344. DOI: 10.17586/0021-3454-2024-67-4-338-344.

RANDOM NUMBER GENERATION FOR INTERACTIVE APPLICATIONS USING EXTERNAL SENSORS

D. A. Bulgakov

*St. Petersburg State University of Aerospace Instrumentation, St. Petersburg, Russia
dmbulg@gmail.com*

Abstract. A method is presented for obtaining pseudo-random numbers to be used further in the development of interactive applications on the Unity engine with the collection of information from pressure and color sensors connected to the Arduino microcontroller. The method involves using the results of periodic measurements of pressure, temperature, illumination, and colors on RGB channels in a room, bit shifting them by a random number of digits, obtaining the “grain” of a pseudo-random number generator by taking the remainder after comparing the number with the current UNIX time. An application is been developed that implements the proposed method of generating pseudorandom numbers. The uniformity of distribution is checked and the correlation coefficient is assessed using a sample of random numbers.

Keywords: random numbers, pseudo-random numbers generator, interactive applications, pressure sensor, color sensor, Arduino, Unity

For citation: Bulgakov D. A. Random number generation for interactive applications using external sensors. *Journal of Instrument Engineering*. 2024. Vol. 67, N 4. P. 338—344 (in Russian). DOI: 10.17586/0021-3454-2024-67-4-338-344.

Введение. Решение таких задач, как генерация одноразовых паролей и хэш-сумм, определение победителя в различных конкурсах и лотереях, генерация территорий в многопользовательских играх и метавселенных, невозможно представить без надежного генератора случайных чисел [1].

В отличие от физических процессов в природе, математические операции, выполняемые на компьютере, являются детерминированными, поэтому добиться истинной случайности от сгенерированных чисто алгоритмическими методами чисел невозможно. Сгенерированные на компьютере числа принято называть псевдослучайными, а генератор псевдослучайных чисел обозначать как ГПСЧ [2].

Использовать обычные арифметические операции для генерации псевдослучайных чисел, в частности в методе середины квадрата, впервые предложил Джон фон Нейман [3]. Конечно, метод не дает истинно случайных чисел, но доказательство того, что алгоритмические методы не могут предоставить истинную случайность результатов, наглядно подтвердил Дональд Кнут после реализации на компьютере сложного многошагового алгоритма „Алгоритм К“, который довольно быстро сошелся к одному 10-значному числу [4].

Алгоритмы ГПСЧ совершенствовались с течением времени. На сегодняшний день существует не один десяток достаточно надежных ГПСЧ, наиболее известны: Вихрь Мерсенна, используемый в функции RAND языка программирования Python, субтрактивный метод Кнута, используемый в методе Random языка C#, и алгоритм Fortuna, используемый в продуктах корпорации Apple. Тем не менее, любой ГПСЧ с ограниченными ресурсами рано или поздно заикливается — начинает повторять одну и ту же последовательность чисел [5—7]. Длина циклов ГПСЧ в среднем составляет $2^{n/2}$, где n — объем памяти, который занимает внутреннее состояние алгоритма.


Для создания ГПСЧ, который удовлетворял бы равномерному закону распределения, обладал сходимостью моментов и позволял получать длительный период случайной последовательности, применения только алгоритма генерации недостаточно — в уравнения требуется включать числовые данные, полученные от различных недетерминированных событий, происходящих в окружающем мире [8].

Далее представлен вариант генератора псевдослучайных чисел на основе внешних данных, который может быть использован при разработке любых интерактивных приложений на игровом движке.

Описание предлагаемого решения. Для практических задач, не предъявляющих критических требований к безопасности, можно ограничиться измерением различных физических величин из окружающей среды. Эти данные затем будут преобразовываться в целые числа и использоваться в качестве параметров алгоритма ГПСЧ в программе, написанной на языке C#. Для демонстрации работы предлагаемого метода был взят микроконтроллер Arduino Uno R3. Схематичное изображение платы Arduino Uno с подписанными контактами приведено на рис. 1, к ней подключались [9—11]:

- 1) датчик атмосферного давления и температуры BMP280;
- 2) датчик цвета TCS3472.

В среде разработки Arduino IDE реализовано приложение „bmp280_plus_tcs3472.ino“ для инициализации и настройки датчиков, а на игровом движке Unity создано тестовое приложение „BMPTCSRNG“ — для считывания данных с датчиков.



Модуль измерения атмосферного давления и температуры построен на базе чипа BOSH BMP280 и заранее откалиброван на заводе (табл. 1). Модуль предоставляет пользователю два последовательных интерфейса обмена данными: SPI и I2C. К плате ArduinoUno датчик BMP280 подключается следующим образом: VCC—3.3V; GND—GND; SCL—A5; SDA—A4.

Таблица 1

Назначение контактов датчика BMP280

Контакт	Назначение
VCC	Питание 3,3 В
GND	Обеспечение нулевого потенциала (Земля)
SCK (SCL)	Ввод частоты по интерфейсам I2C и SPI
SDI (SDA)	Ввод данных по интерфейсам I2C и SPI
CSB	Выбор активного интерфейса I2C
SDO	Изменение адреса I2C

Датчик TCS3472 способен выводить данные о цвете поверхности по каналам R, G, B, C, а также интенсивности света, измеряемой в люксах (табл. 2). Датчик использует интерфейс I2C для передачи данных. К плате ArduinoUno датчик TCS3472 подключается следующим образом: VIN—3.3V; GND—GND; SCL—A5; SDA—A4.

Таблица 2

Назначение контактов датчика TCS34725

Контакт	Назначение
VIN	Питание 3,3/5 В
GND	Обеспечение нулевого потенциала (Земля)
3V3	Вывод напряжения 3,3 В
SCL	Ввод частоты по интерфейсу I2C
SDA	Ввод данных по интерфейсу I2C
INT	Выход прерывания, активный низкий уровень
LED	Вход управления светодиодами

Для получения показаний с датчиков требуется подключение библиотек „Adafruit_BMP280.h“ и „Adafruit_TCS34725.h“ с открытым исходным кодом.

Ниже приведен фрагмент кода скрипта обработки показаний с датчиков — метод GetTemperatureInfo(), считывающего показания температуры:

```
public void GetTemperatureInfo()
{
    float number = FindNumberInString(outputLines[0]);
    temperatureValue.text = number.ToString();
}
```

Значение температуры записывается в текстовое поле — элемент пользовательского интерфейса, который отображается на экране. Поскольку строка содержит не только числа, но

также текст и символы, то применяется метод-парсер FindNumberInString, удаляющий из строки все буквы и знаки. Вид интерфейса приложения с полученными данными приведен на рис. 2.




Рис. 2

Получение новых данных сопровождается выполнением следующей последовательности действий: закрытие последовательного порта, обнуление списка данных и открытие порта. Эти операции выполняются в методе ClearData.

Предлагаемый метод генерации псевдослучайных чисел включает следующие шаги:

- 1) сформировать массив числовых значений $a_i, i = \overline{1, n}$ на основе показаний датчиков, $n = 6$;
- 2) выполнить побитовый сдвиг влево значений $a_i, i = \overline{1, n}$ на r разрядов. Значение r разыгрывается методом Random.Next() — выполняется генерация псевдослучайного целого числа в диапазоне типа Integer;
- 3) выбрать одно из значений $a_i, i = \overline{1, n}$ методом Random.Next();
- 4) зафиксировать метку текущего времени $m(t)$ — UNIX-время;
- 5) если $m(f) > a_i$ и $a_i \neq 0$, то вычислить $A = m(f) \bmod a_i$, иначе $A = a_i \bmod m(f)$;
- 6) считать полученное значение A итоговым „зерном“ ГПСЧ;
- 7) сгенерировать на основании итогового „зерна“ псевдослучайное число, используя метод Random.Next(d), где d — правая граница диапазона.

Генерация случайного числа в приложении запускается нажатием на кнопку „Сгенерировать“ (см. рис. 2). Итоговое 32-битное число типа int выводится в текстовое поле в нижней части экрана.

Тестирование ГПСЧ. Как известно, ГПСЧ должны удовлетворять следующим требованиям [12, 13]:

- числа в генерируемой последовательности должны быть равномерно распределены и независимы, что проверяется статистическими тестами;
- период последовательности должен иметь возможно большую длину.

Равномерность распределения по выборке $A_1, A_2, \dots, A_n$ проверяется путем определения эмпирических вероятностных характеристик — моментов и параметров распределения, а также их сравнения с теоретическими характеристиками распределения.

Для проверки равномерности распределения применялся частотный тест, последовательность его проведения следующая [14].

1. Получить выборку ГПСЧ: $A_1, A_2, \dots, A_n$.
2. Разбить интервал ГПСЧ $[0, d]$ на K равных отрезков.
3. Подсчитать, сколько чисел попало в каждый из K отрезков, т.е. найти число попаданий $n_1, n_2, \dots, n_k$.

4. Найти относительную частоту попадания в отрезки:

$$\hat{p}_1 = \frac{n_1}{n}, \hat{p}_2 = \frac{n_2}{n}, \dots, \hat{p}_K = \frac{n_k}{n}.$$

5. Построить гистограмму частот $\hat{p}_1, \hat{p}_2, \dots, \hat{p}_K$.

6. Оценить по полученной гистограмме сходимость каждой частоты $\hat{p}_i$ к вероятности $p = \frac{1}{K}$.

Согласно закону больших чисел, значения $\hat{p}_1, \hat{p}_2, \dots, \hat{p}_K$ должны сходиться к p при $n \rightarrow \infty$.

Гистограмма частотного теста на выборке из 16 000 значений предложенного ГПСЧ приведена на рис. 3.




Рис. 3

Проверка статистической независимости ГПСЧ выполнена с помощью оценки линейной корреляции между величинами A_i и A_{i+s} , при $s \geq 1$, где s — шаг, с которым выбираются случайные числа [15—17].

На рис. 4 приведен график зависимости коэффициента корреляции R от длины случайной последовательности, из которого видно, что $R \rightarrow 0$.




Рис. 4

Заключение. Предложенный метод генерации псевдослучайных чисел позволяет получать и применять разнородные данные из внешних источников с помощью известных методов в интерактивных приложениях, построенных на игровом движке Unity.

Метод предполагает использование результатов периодических измерений давления, температуры, освещенности и цветов по каналам RGB в помещении и получении „зерна“ генератора псевдослучайных чисел после применения определенных операций над измерениями.

Предложенный метод позволяет создать генератор псевдослучайных чисел, близкий по своим характеристикам к истинному источнику энтропии [18], что показало тестирование на равномерное распределение и отсутствие корреляции между случайными числами, выдаваемых генератором.

СПИСОК ЛИТЕРАТУРЫ

1. Андреева Е. Г., Молчалин В. А. Генератор псевдослучайных чисел в игровых механиках // Россия молодая: передовые технологии — в промышленность. 2023. № 1. С. 3—9. DOI 10.25206/2310-4597-2023-1-3-9. EDN GIMLYI.
2. Чайко В. И. Накопление случайности в генераторах псевдослучайных чисел // Исследования молодых ученых: Матер. XXXII Междунар. науч. конф. Казань, 20—23 февраля 2022 г. Казань: Молодой ученый, 2022. С. 10—15. EDN IPCVOY.
3. Von Neumann J. Various techniques use disconnection with random digits // National Bureau of Standards Applied Mathematics Series. 1951. N 12. P. 36—38.
4. Кнут Д. Э. Искусство программирования. Т. 2. Получисленные алгоритмы. 3-е изд. М.: Диалектика, 2020. 832 с.
5. Белов А. А., Калиткин Н. Н., Тинтул М. А. Ненадежность известных генераторов псевдослучайных чисел // Журнал вычислительной математики и математической физики. 2020. Т. 60, № 11. С. 1807—1814. DOI 10.31857/S0044466920110046. EDN CTJCWS.
6. Орлов М. А., Нечаев К. А., Иванов Н. А. Проблемы криптостойкости в современных ГПСЧ // Наука и бизнес: пути развития. 2022. № 4(130). С. 53—58. EDN SMUPYE.
7. Романков С. В. Методы генерации псевдослучайных чисел // Молодой ученый. 2022. № 33(428). С. 4—10. EDN EHNDWM.
8. Dhirendra K., Chaurasia U., Mishra S. Design of True Random Number Generator Using Fingerprint as an Entropy Source and Its Implementation in S-Box // J. of Circuits, Systems and Computers. 2021. Vol. 30, N 15. Art. no 2150285.
9. Arduino Software. Официальная документация и спецификации модели UnoR3 [Электронный ресурс]: <<https://docs.arduino.cc/hardware/uno-rev3>>. (дата обращения: 21.12.2023).
10. 3DiY (Тридай). Датчик атмосферного давления BMP280 [Электронный ресурс]: <<https://3d-diy.ru/wiki/arduino-datchiki/sensor-bmp280/>>. (дата обращения: 21.12.2023).
11. Wave share Electronics. TCS34725 Color Sensor User Manual [Электронный ресурс]: <https://www.waveshare.com/w/upload/b/bb/TCS34725_Color_Sensor_user_manual_en.pdf>. (дата обращения: 21.12.2023).
12. Дроздова И. И., Жилин В. В. Генераторы случайных и псевдослучайных чисел // Технические науки в России и за рубежом: Матер. VII Междунар. науч. конф. М., 2017. С. 13—16.
13. Гончарук В. С., Атаманов Ю. С., Гордеев С. Н. Методы генерации случайных чисел // Молодой ученый. 2017. № 8(142). С. 20—23.
14. Кутузов О. И., Татарникова Т. М. Из практики применения метода Монте-Карло // Заводская лаборатория. Диагностика материалов. 2017. Т. 83, № 3. С. 65—70.
15. Колесова Н. А. Оценка качества генераторов последовательностей случайных чисел // Вестник Астраханского государственного технического университета. Серия: Управление, вычислительная техника и информатика. 2011. № 1. С. 119—123.
16. Григорьев А. Ю. Методы тестирования генераторов случайных и псевдослучайных последовательностей // Ученые записки УлГУ. 2017. № 1. С. 22—28.

17. Пахомов В. А., Титовская Е. П. Исследование надежности генератора псевдослучайных последовательностей // Юный ученый. 2020. № 4(34). С. 70—75.
18. Зубков А. М. Энтропия как характеристика качества случайных последовательностей // Математические вопросы криптографии. 2021. Т. 12, № 3. С. 31—48. DOI 10.4213/mvk374. EDN RJVEOY.

Сведения об авторе

Дмитрий Алексеевич Булгаков — Санкт-Петербургский государственный университет аэрокосмического приборостроения, кафедра прикладной информатики (Кафедра 41); старший преподаватель; E-mail: dmbulg@gmail.com

Поступила в редакцию 04.12.23; одобрена после рецензирования 11.12.23; принята к публикации 08.02.24.

REFERENCES

1. Andreeva E.G., Molchalin V.A. *Young Russia: advanced technologies into industry*, 2023, no. 1, pp. 3–9, DOI 10.25206/2310-4597-2023-1-3-9. (in Russ.)
2. Chayko V.I. *Issledovaniya molodykh uchenykh* (Research by Young Scientists), Proc. of the XXXII Intern. Scientific Conf., February 20–23, 2022, Kazan, 2022, pp. 10–15. (in Russ.)
3. Von Neumann J. *National Bureau of Standards Applied Mathematics Series*, 1951, no. 12, pp. 36–38.
4. Knuth D. *The Art of Computer Programming, vol. 2: Seminumerical Algorithms*, Massachusetts, Addison-Wesley, 1997, 762 p.
5. Belov A.A., Tintul M.A., Kalitkin N.N. *Computational Mathematics and Mathematical Physics*, 2020, no. 11(60), pp. 1747–1753, DOI 10.31857/S0044466920110046.
6. Orlov M.A., Nechaev K.A., Ivanov N.A. *Science and business: ways of development*, 2022, no. 4(130), pp. 53–58. (in Russ.)
7. Romankov S.V. *Young scientist*, 2022, no. 33(428), pp. 4–10. (in Russ.)
8. Dharendra K., Chaurasia U., Mishra S. *Journal of Circuits, Systems and Computers*, 2021, no. 15(30), pp. 2150285.
9. *Arduino Software*, <https://docs.arduino.cc/hardware/uno-rev3>.
10. <https://3d-diy.ru/wiki/arduino-datchiki/sensor-bmp280/>. (in Russ.)
11. Wave share Electronics. *TCS34725 Color Sensor User Manual*, https://www.waveshare.com/w/upload/b/bb/TCS34725_Color_Sensor_user_manual_en.pdf.
12. Drozdova I.I., Zhilin V.V. *Tekhnicheskiye nauki v Rossii i za rubezhom* (Technical Sciences in Russia and Abroad), Materials of the VII Intern. Scientific Conf., Moscow, 2017, pp. 13–16. (in Russ.)
13. Goncharuk V.S., Atamanov Yu.S., Gordeev S.N. *Young scientist*, 2017, no. 8(142), pp. 20–23. (in Russ.)
14. Kutuzov O.I., Tatarnikova T.M. *Factory laboratory. Diagnostics of materials*, 2017, no. 3(83), pp. 65–70. (in Russ.)
15. Kolesova N.A. *Vestnik of Astrakhan State Technical University. Series: Management, Computer Sciences and Informatics*, 2011, no. 1, pp. 119–123. (in Russ.)
16. Grigoriev A.Yu. *Scientific Notes of ULSU. Series: Mathematics and Information Technology*, 2017, no. 1, pp. 22–28. (in Russ.)
17. Pakhomov V.A., Titovskaya E.P. *Young scientist*, 2020, no. 4(34), pp. 70–75. (in Russ.)
18. Zubkov A.M. *Mathematical Aspects of Cryptography*, 2021, no. 3(12), pp. 31–48, DOI 10.4213/mvk374. (in Russ.)

Data on author

Dmitriy A. Bulgakov — St. Petersburg State University of Aerospace Instrumentation Department of Applied Informatics (Department 41); Senior Lecturer; E-mail: dmbulg@gmail.com

Received 04.12.23; approved after reviewing 11.12.23; accepted for publication 08.02.24.

МЕТОДЫ БАЛАНСИРОВКИ НАГРУЗКИ В ИНФОРМАЦИОННЫХ СИСТЕМАХ

Е. Д. АРХИПЦЕВ*, Н. С. МОКРЕЦОВ

*Санкт-Петербургский государственный электротехнический университет
„ЛЭТИ“ им. В.И. Ульянова (Ленина), Санкт-Петербург, Россия***lokargenia@gmail.com*

Аннотация. Обсуждается проблема балансировки нагрузки в крупных информационных системах. В условиях высокой нагрузки информационных систем, через которые проходят большие объемы данных, и увеличения числа пользователей, становится критически важным эффективное распределение нагрузки между ресурсами системы. Рассматриваются алгоритмы балансировки нагрузки, функционирование которых зависит от подхода (централизованного или распределенного) к построению архитектуры информационной системы. Описаны разные типы архитектуры построения информационных систем с выделением особенностей механизмов балансировки нагрузки для них. Демонстрируются результаты натурного эксперимента на виртуальных серверах по оценке эффективности алгоритмов балансировки нагрузки. Вычислительные характеристики серверов задавались разными и ожидаемое время выполнения запроса разыгрывалось случайным образом, что делает условия эксперимента близкими к реальным.

Ключевые слова: высоконагруженная система, балансировка нагрузки, архитектура системы, распределение ресурсов, алгоритмы балансировки, натурный эксперимент

Ссылка для цитирования: Архипцев Е. Д., Мокрецов Н. С. Методы балансировки нагрузки в информационных системах // Изв. вузов. Приборостроение. 2024. Т. 67, № 4. С. 345—351. DOI: 10.17586/0021-3454-2024-67-4-345-351.

METHODS OF LOAD BALANCING IN HIGHLY LOADED SYSTEMS

E. D. Arkhipsev*, N. S. Mokretsov

*St. Petersburg Electrotechnical University, St. Petersburg, Russia***lokargenia@gmail.com*

Abstract. The problem of load balancing in large information systems is discussed. In conditions of high load of information systems caused by big data and an increase in the number of users, effective distribution of the load between system resources becomes critical. Existing load balancing algorithms are considered, considering a centralized or distributed approach to building the architecture of an information system. A description of different architectures for building information systems is given, highlighting the features of load balancing mechanisms for them. The results of a full-scale experiment on virtual servers to evaluate the effectiveness of load balancing algorithms are presented. The computing characteristics of the servers were set differently and the expected request execution time was played out randomly, which makes the experiment close to real conditions.

Keywords: highly loaded system, load balancing, system architecture, resource allocation, balancing algorithms, full-scale experiment

For citation: Arkhipsev E. D., Mokretsov N. S. Methods of load balancing in highly loaded systems. *Journal of Instrument Engineering*. 2024. Vol. 67, N 4. P. 345—351 (in Russian). DOI: 10.17586/0021-3454-2024-67-4-345-351.

Введение. Важным этапом разработки высоконагруженных информационных систем является выбор механизма балансировки нагрузки.

Основная цель балансировки нагрузки заключается в обеспечении гарантированной безотказности и быстродействия информационной системы, которая достигается решением следующих задач:

- эффективное использование вычислительных ресурсов;
- обеспечение гарантированной пропускной способности системы;

- обеспечение гарантированного времени отклика системы;
- предотвращение перегрузки вычислительных ресурсов.

Независимо от того, является ли высоконагруженная информационная система распределенной или централизованной, балансировка нагрузки необходима — механизм ее реализации будет соответствовать архитектуре системы. Среди основных типов архитектуры информационных систем можно выделить:

- монолитную архитектуру [1];
- сервисно-ориентированную архитектуру (SOA) [2];
- микросервисную архитектуру [3];
- событийно-ориентированную архитектуру (EDA) [4].

При монолитной архитектуре все части приложения, включая пользовательский интерфейс, бизнес-логику и слой данных, развертываются и запускаются в одном процессе или на одном сервере [5].

При централизованном подходе один узел или группа узлов управляют передачей служебной информации, на основании которой происходит сбалансированное распределение нагрузки в системе. Недостаток такого подхода заключается в возможной перегрузке узла с централизованным принятием решения — так называемой точки отказа [6].

Остальные типы архитектуры — сервисно-ориентированная, микросервисная, событийно-ориентированная — представляют собой распределенные решения. Компоненты приложения при сервисно-ориентированной архитектуре представлены в виде автономных служб, взаимодействующих посредством стандартизированных протоколов. В случае микросервисной архитектуры приложение состоит из множества небольших автономных сервисов, каждый из которых решает конкретную бизнес-задачу. При событийно-ориентированной архитектуре компоненты системы могут обмениваться событиями для управления и обработки изменений в системе [7—10].

При использовании распределенного подхода все участвующие в реализации функций балансировки нагрузки узлы обмениваются служебной информацией, на основании которой принимается решение с учетом собственных ресурсов узла [11].

Балансировщики нагрузки необходимы крупным компаниям, таким как банки, страховые и торговые корпорации, телекоммуникационные компании (системы биллинга, хостинга, всевозможные веб-сервисы и социальные сервисы). Эти компании используют сложные бизнес-приложения (ERP, CRM-системы и др.), и их деятельность напрямую зависит от надежности инфраструктуры [12, 13].

В настоящей статье с помощью натурального эксперимента оценивается эффективность известных алгоритмов балансировки нагрузки.

Алгоритмы балансировки нагрузки. Каждая архитектура информационной системы использует собственный балансировщик нагрузки. Определяется список доступных для балансировщика нагрузки серверов, которым при установке назначаются уникальные идентификаторы процесса (PID) [14].

Пусть $L = \{p_1, p_2, \dots, p_n\}$ является списком из n серверов, где p_i — i -й сервер. Когда запрос пользователя отправляется на обслуживание в информационную систему, алгоритм балансировки нагрузки выбирает сервер (т.е. его PID), который будет использован для выполнения запроса. Во время работы выбор PID будет зависеть от алгоритма балансировки нагрузки [15]. Приведем известные алгоритмы балансировки нагрузки.

Алгоритм случайного результата (Randomized) [16]. Согласно алгоритму, новый запрос пользователя отправляется на случайно выбранный узел — сервер из имеющейся совокупности ресурсов. Таким образом, случайным образом выбирается натуральное число x в диапазоне $[1, n]$ и $p_i = p_x$, где p_i служит выходным значением (PID) сервера в алгоритме балансировки, а p_x — элементом на позиции x в списке L .

При случайном распределении нагрузки с течением времени ресурсы будут использоваться примерно одинаково, поскольку вероятность выбора каждого узла одинакова. Для алгоритма не требуется задавать какую-либо связь или извлекать информацию о состоянии серверов с целью балансирования нагрузки.

Алгоритм циклического перебора [17]. Согласно алгоритму, запрос отправляется следующему доступному узлу в очереди. При инициализации балансировщика выбирается случайное целочисленное значение x , которое определяет первоначальную балансировку нагрузки, а далее номер сервиса определяется по итерационному алгоритму.

Пусть k — число запросов, прошедших через балансировщик нагрузки, r — количество ожидающих запросов, тогда сначала определяется результирующее число балансировки $y = k + r$, а потом номер сервиса i для обработки запроса $i = (y \bmod n) + 1$. Операция $\bmod$ — нахождение остатка от деления — позволяет циклически выбирать элементы из списка L .

Циклический перебор не учитывает времени выполнения запроса, что приводит к повышению времени отклика, неэффективному использованию и распределению ресурсов. Эта проблема становится актуальной при различных значениях времени выполнения запроса или мощности серверов.

Алгоритм min-max [18] определяет минимальное время выполнения актуальных запросов и направляет запрос с наибольшим временем выполнения на узел с минимальным временем выполнения. Алгоритм основан на предположении, что сервер с меньшей рабочей нагрузкой имеет более высокую вероятность получения запроса с меньшим временем вычисления, чем сервер с более высокой рабочей нагрузкой. При выборе сервера балансировщик нагрузки вычисляет вероятность распределения зависимости от загруженности сервера и определяет PID из этого распределения

$$P(i) = \frac{a_i}{\sum_{i=1}^n a_i},$$

где $P(i)$ — вероятность выбора сервера p_i ; $a_i = 1 - w(p_i)$ — весовой коэффициент распределения нагрузки i -го узла; $w(p_i)$ — рабочая нагрузка сервера p_i .

Обсуждение результатов. Для экспериментального сравнения алгоритмов балансировки нагрузки была развернута система, состоящая из трех виртуальных серверов с разной производительностью.

Любой запрос пользователя сначала направляется на балансировщик нагрузки — программный контроллер, предназначенный для последовательного выполнения следующих задач:

- 1) прием запросов от клиентов;
- 2) выбор сервера для обработки запроса клиента;
- 3) перенаправление запроса на выбранный сервер;
- 4) прием ответа от сервера на клиентский запрос;
- 5) перенаправление ответа сервера на запрос клиенту
- 6) мониторинг загруженности серверов информационной системы.

Каждый запрос представляет собой сессию пользователя, которая состоит из последовательности операций, необходимых для его выполнения. Поэтому время выполнения запросов задавалось случайным образом в виде функции распределения или функции плотности вероятностей и оценивалось как период между моментом поступления запроса на вход балансировщика нагрузки и моментом появления ответа на этот запрос на выходе сервера.

Сессия пользователя информационной системы может быть представлена временной диаграммой, отражающей выполнение задания запроса на сервере (рис. 1). Диаграмма состоит из периодов, когда вычислительные ресурсы сервера заняты выполнением задания и

интервалов времени, в течение которых процесс находится в состоянии ожидания освобождения ресурса.




Рис. 1

На рис. 2 приведены результаты балансировки нагрузки по рассмотренным выше алгоритмам (d — число запросов, отклоненных серверами из-за большой нагрузки; производительность наименее мощного сервера оценивалась в 20 баллов, самого мощного — в 30 баллов).




Рис. 2

На рис. 2, а, где проиллюстрирована балансировка нагрузки по алгоритму случайного результата, первый сервер — низкопроизводительный (синяя кривая) — показал ожидаемый результат. Однако второй сервер (оранжевая кривая) лучше справлялся с нагрузкой, по сравнению с самым мощным сервером (зеленая кривая). Относительно результатов эксперимента балансировки нагрузки по алгоритму случайного результата можно сделать следующий вывод: несмотря на незначительное время вычисления PID сервера, выбранного для обработ-

ки запроса, этот алгоритм малоэффективен, когда различается производительность серверов и запросы требуют разного времени выполнения.

Из графика для балансировки нагрузки по алгоритму циклического перебора (рис. 2, б) видно, что число отказов зависит от мощности сервера. Однако этот алгоритм не учитывает время, затраченное на выполнение запросов, что приводит к простоям мощного сервера и отказу в обработке запросов на низкопроизводительном сервере.

Как видно из рис. 2, в, при балансировке нагрузки с применением алгоритма min-max число отброшенных запросов выровнялось на каждом сервере, а их общее число уменьшилось. Поскольку алгоритм учитывает текущее состояние серверов, это позволило равномерно распределять нагрузку по серверам.

Заключение. Рассмотрены типы архитектуры информационных систем и методы балансировки нагрузки, применяемые для распределения запросов пользователей по серверам системы с учетом требований к времени обработки и потерям.

Приведены особенности основных алгоритмов распределения нагрузки, таких как случайный результат, циклический перебор и min-max. По результатам натурного эксперимента на виртуальных серверах сделаны следующие выводы по эффективности алгоритмов балансировки нагрузки:

- алгоритм на базе случайного результата обеспечивает наименьшее время принятия решения о распределении нагрузки;
- алгоритм min-max показывает самое долгое время принятия решения о распределении нагрузки, поскольку решение зависит от состояния каждого сервиса системы;
- алгоритмы циклического перебора и случайного результата не учитывают текущей загруженности серверов и с увеличением нагрузки запросы пользователя начинают получать отказы в обслуживании;
- в условиях, близких к реальным, при которых различается производительность серверов и для обслуживания запросов требуется разное время обработки, алгоритмы случайного результата и циклического перебора оказались неэффективны;
- алгоритм min-max, благодаря своим особенностям вычисления загруженности серверов, справляется с балансировкой нагрузки лучше алгоритмов случайного результата и циклического перебора.

СПИСОК ЛИТЕРАТУРЫ

1. Амиров С. Н. Особенности разработки высоконагруженных систем // International Journal of Open Information Technologies. 2020. Т. 8, № 8. С. 32—47.
2. Подольный В. П. Архитектура высоконагруженных систем. Системы сбора информации, распределенные системы управления, системы реального времени. М.: САМ Полиграфист, 2022. 160 с.
3. Мычко С. И. Микросервисная архитектура // Информационные технологии. 2019. С. 166—168.
4. Беллемар А. Создание событийно-управляемых микросервисов. СПб: BHV, 2022. 320 с.
5. Радостаев Д. К., Никитина Е. Ю. Стратегия миграции программного кода из монолитной архитектуры в микросервисы // Вестник Пермского университета. Математика. Механика. Информатика. 2021. Вып. 2(53). С. 65—68. DOI: 10.17072/1993-0550-2021-2-65-68.
6. Мартин Р. Чистая архитектура. Искусство разработки программного обеспечения. СПб: Питер, 2018. 352 с.
7. Богатырев В. А., Лисичкин Д. Э. Оптимизация периодичности инициализации контроля на основе дублированных вычислений // Программные продукты и системы. 2019. № 2. С. 214—220. DOI: 10.15827/0236-235X.126.214-220.
8. Сергеева И. И., Белильщикова А. А. Сервисно-ориентированная архитектура (SOA): Опыт внедрения // Научные Записки ОрелГИЭТ. 2012. № 1. С. 440—444.

9. Татарникова Т. М., Архипцев Е. Д., Кармановский Н. С. Определение размера кластера и числа реплик высоконагруженных информационных систем // Изв. вузов. Приборостроение. 2023. Т. 66, № 8. С. 646—651. DOI: 10.17586/0021-3454-2023-66-8-646-651.
10. Ньюмен С. Создание микросервисов. СПб: Питер, 2018. 304 с.
11. Татарникова Т. М., Архипцев Е. Д. Алгоритм контроллера нечеткой логики для размещения файлов в системе хранения данных // Науч.-техн. вестн. информационных технологий, механики и оптики. 2023. Т. 23, № 6. С. 1171—1177. DOI: 10.17586/2226-1494-2023-23-6-1171-1177.
12. Бороздин Н. М. Исследование и анализ практических преимуществ микросервисной архитектуры для современных веб-приложений // Инновационные научные исследования в современном мире. 2023. С. 279—284.
13. Татарникова Т. М., Архипцев Е. Д. Определение числа реплик распределенного хранения больших данных // Междунар. конф. по мягким вычислениям и измерениям. 2023. Т. 1. С. 305—308.
14. Malavika R., Valarmathi M. L. Adaptive Server Load Balancing in SDN Using PID Neural Network Controller // Computer Systems Science & Engineering. 2022. Vol. 42, N 1. P. 229—243. DOI: 10.32604/csse.2022.020947.
15. Zagarese Q. et al. Improving data-intensive EDA performance with annotation-driven laziness // Science of Computer Programming. 2015. Vol. 97. P. 266—279. DOI: 10.1016/j.scico.2014.03.007.
16. Mitzenmacher M. The power of two choices in randomized load balancing // IEEE Transact. on Parallel and Distributed Systems. 2001. Vol. 12, N 10. P. 1094—1104. DOI: 10.1109/71.963420.
17. Kaur S. et al. Round-robin based load balancing in Software Defined Networking // 2nd Intern. Conf. on Computing for Sustainable Global Development (INDIACom). New Delhi, India, 2015. P. 2136—2139.
18. Maqsood Z. S. Kh., Ali T., Bilal M., Madani K., Khan S., ur Rehman A. A Load Balanced Task Scheduling Heuristic for Large-Scale Computing Systems // Computer Systems Science and Engineering. 2019. N 1. P. 1—12. DOI: 10.32604/csse.2019.34.079.

Сведения об авторах

- Евгений Дмитриевич Архипцев** — аспирант; Санкт-Петербургский государственный электротехнический университет „ЛЭТИ“ им. В.И. Ульянова (Ленина), кафедра информационных систем; E-mail: lokargenia@gmail.com
- Никита Сергеевич Мокрецов** — аспирант; Санкт-Петербургский государственный электротехнический университет „ЛЭТИ“ им. В.И. Ульянова (Ленина), кафедра информационных систем; E-mail: nikitamokrecov6374@gmail.com

Поступила в редакцию 04.12.23; одобрена после рецензирования 08.12.23; принята к публикации 08.02.24.

REFERENCES

1. Amirov S.N. *International Journal of Open Information Technologies*, 2020, no. 8(8), pp. 32—47. (in Russ.)
2. Podolny V.P. *Arkhitektura vysokonagruzhenykh sistem. Sistemy sbora informatsii, raspredelennyye sistemy upravleniya, sistemy real'nogo vremeni* (Architecture of Highly Loaded Systems. Information Collection Systems, Distributed Control Systems, Real-Time Systems), Moscow, 2022, 160 p. (in Russ.)
3. Mychko S.I. *Information Technology*, 2019, pp. 166—168. (in Russ.)
4. Bellemare A. *Building Event-Driven Microservices*, O'Reilly Media, 2020, 324 p.
5. Radostev D.K., Nikitina E.Yu. *Bulletin of Perm University. Mathematics. Mechanics. Computer Science*, 2021, no. 2(53), pp. 65—68, DOI: 10.17072/1993-0550-2021-2-65-68. (in Russ.)
6. Martin R.C. *Clean Architecture. A Craftsman's Guide to Software Structure and Design*, 2017.
7. Bogatyrev V.A., Lisichkin D.E. *Software & Systems*, 2019, no. 2, pp. 214—220. DOI: 10.15827/0236-235X.126.214-220. (in Russ.)
8. Sergeeva I.I., Belilshchikova A.A. *Scientific Notes of the Oryol State Institute of Economics and Trade*, 2012, no. 1, pp. 440—444. (in Russ.)
9. Tatarnikova T.M., Arkhipcev E.D., Karmanovskiy N.S. *Journal of Instrument Engineering*, 2023, no. 8(66), pp. 646—651, DOI: 10.17586/0021-3454-2023-66-8-646-651. (in Russ.)
10. Newman S. *Building Microservices*, O'Reilly, 2015.
11. Tatarnikova T.M., Arkhipcev E.D. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*, 2023, no. 6(23), pp. 1171—1177, DOI: 10.17586/2226-1494-2023-23-6-1171-1177. (in Russ.)
12. Borozdin N.M. *Innovatsionnyye nauchnyye issledovaniya v sovremennom mire* (Innovative Scientific Research in the Modern World), Materials of the XIII International Scientific and Practical Conference, Ufa, 2023, pp. 279—284. (in Russ.)
13. Tatarnikova T.M., Arkhipcev E.D. *Mezhdunarodnaya konferentsiya po myagkim vychisleniyam i izmereniyam* (Inter-

- national Conference on Soft Computing and Measurement), 2023, vol. 1, pp. 305–308. (in Russ.)
14. Malavika R., Valarmathi M.L. *Computer Systems Science & Engineering*, 2022, no. 1(42), pp. 229–243, DOI: 10.32604/csse.2022.020947.
 15. Zagarese Q. et al. *Science of Computer Programming*, 2015, vol. 97, pp. 266–279, DOI: 10.1016/j.scico.2014.03.007.
 16. Mitzenmacher M. *IEEE Transactions on Parallel and Distributed Systems*, 2001, no. 10(12), pp. 1094–1104, DOI: 10.1109/71.963420.
 17. Kaur S. et al. *2nd Intern. Conf. on Computing for Sustainable Global Development (INDIACom)*, New Delhi, India, 2015, pp. 2136–2139.
 18. Maqsood Z.S.Kh., Ali T., Bilal M., Madani K., Khan S., ur Rehman A. *Computer Systems Science and Engineering*, 2019, no. 1, pp. 1–12, DOI: 10.32604/csse.2019.34.079.

Data on authors

- Evgeny D. Arkhiptsev** — Post-Graduate Student; St. Petersburg Electrotechnical University, Department of Information Systems; E-mail: lokargenia@gmail.com
- Nikita S. Mokretsov** — Post-Graduate Student; St. Petersburg Electrotechnical University, Department of Information Systems; E-mail: nikitamokrecov6374@gmail.com

Received 04.12.23; approved after reviewing 08.12.23; accepted for publication 08.02.24.

**БАЛАНСИРУЕМАЯ СТРУКТУРА ДАННЫХ
С ПРИОРИТЕТАМИ ЭЛЕМЕНТОВ
В ЗАДАЧЕ МОДЕЛИРОВАНИЯ ДИСКРЕТНЫХ ИСТОЧНИКОВ ИНФОРМАЦИИ**

А. В. АКСЕНОВ

*Санкт-Петербургский государственный университет аэрокосмического приборостроения,
Санкт-Петербург, Россия,
aksenov@guap.ru*

Аннотация. Рассматриваются особенности разработки балансируемой структуры данных, ориентированной на ускоренный доступ к элементам, имеющим высокий приоритет. Подобные структуры могут использоваться в задачах моделирования дискретных источников информации. Предложено самобалансирующееся двоичное дерево поиска, оптимизированное для эффективного хранения и поиска данных на основе приоритетов, коррелирующих с вероятностью порождения символов. Решение позволяет преодолеть ограничения существующих структур данных с учетом требований к памяти и производительности в контексте специфических задач обработки информации.

Ключевые слова: структура данных, ускоренный доступ, двоичное дерево поиска, самобалансирующаяся структура, хранение данных, эффективный поиск данных

Ссылка для цитирования: Аксенов А. В. Балансируемая структура данных с приоритетами элементов в задаче моделирования дискретных источников информации // Изв. вузов. Приборостроение. 2024. Т. 67, № 4. С. 352—358. DOI: 10.17586/0021-3454-2024-67-4-352-358.

**BALANCEABLE DATA STRUCTURE
WITH ELEMENT PRIORITIES IN THE PROBLEM
OF DISCRETE INFORMATION SOURCE MODELING**

A. V. Aksenov

*St. Petersburg State University of Aerospace Instrumentation, St. Petersburg, Russia
aksenov@guap.ru*

Abstract. The features of developing a balanceable data structure focused on accelerated access to elements with high priority are considered. Similar structures can be used in problems of modeling discrete information sources. A self-balancing binary search tree is proposed, optimized for efficient storage and retrieval of data based on priorities that correlate with the probability of symbol generation. The solution overcomes the limitations of existing data structures, taking into account memory and performance requirements in the context of specific information processing tasks.

Keywords: data structure, accelerated access, binary search tree, self-balancing structure, efficient data storage, efficient data retrieval

For citation: Aksenov A. V. Balanceable data structure with element priorities in the problem of discrete information source modeling. *Journal of Instrument Engineering*. 2024. Vol. 67, N 4. P. 352—358 (in Russian). DOI: 10.17586/0021-3454-2024-67-4-352-358.

Введение. В ряде задач, связанных с программной обработкой дискретных данных, возникает потребность в структуре, обеспечивающей хранение элементов некоторого заданного множества вкупе с некоторой информацией о них. При этом зачастую важную роль играет эффективность выполнения с этой структурой таких операций, как добавление и поиск.

Очевидно: если объем данных достаточно велик, а мощность множества возможных значений невелика, наиболее частой операцией, совершаемой со структурой данных, будет поиск некоторого элемента по его ключу. При этом, если предположить, что востребован-

ность элементов различается, то необходимо ускорить доступ именно к наиболее востребованным элементам. В частности, необходимость решения подобной задачи возникает при контекстном моделировании дискретных источников информации. При этом состояние источника определяется контекстом порожденных им символов выходного алфавита. Для каждого состояния задается вероятностное распределение возможных выходных символов, порождаемых при нахождении в данном состоянии. При этом задачей контекстного моделирования (поскольку набор состояний моделируемого источника заранее неизвестен) является получение априорной оценки вероятностного интервала для символа, который был порожден. Для символов с высокой вероятностью порождения целесообразно ускорить нахождение оценки интервала.

Специфика задачи накладывает ряд ограничений на физическую реализацию структуры данных. Так, объем памяти, занимаемый моделью, чрезвычайно велик. Он зависит от порядка моделирования, т.е. длины контекста, учитываемого при задании состояний модели, и ограничен сверху величиной

$$N_{\text{sym}}^{\text{ord}}(V_{\text{stat}} + V_{\text{data}}), \quad (1)$$

где N_{sym} — число символов входного алфавита; ord — порядок моделирования; V_{stat} — размер статистической информации в одиночном элементе; V_{data} — размер полезной информации в одиночном элементе.

Порядок моделирования может быть и неограниченным, тогда число состояний источника (а соответственно и размер модели) бесконечно.

Поскольку набор состояний источника заранее не известен, невозможно предсказать и размер модели, которая будет использована, даже когда осуществляется моделирование контекста конечной длины. Кроме того, многие состояния источника будут посещены столь малое число раз, что накопленная статистика будет крайне невелика. Также вероятны случаи, когда число различных порождаемых символов для состояния чрезвычайно мало. Отсюда следует практическое требование, чтобы структура данных, реализуемая для каждого состояния, занимала возможно меньший объем памяти, желательно пропорциональный количеству статистической информации, который она хранит.

Из этих соображений целесообразно отказаться от реализации структуры данных на основе хэш-таблиц, хотя значения константного времени добавления и поиска элемента следует признать приемлемыми.

Второе ограничение связано с тем, что, как было отмечено выше, задачей контекстного моделирования является оценивание вероятностного интервала порожденного символа, а для ее нахождения необходимо вычислить функцию от приоритетов других элементов структуры.

В настоящей работе предлагается структура, представляющая собой самобалансирующееся двоичное дерево поиска, хранящее данные в узлах, и вводится понятие балансировки дерева по весу.

Обзор самобалансирующихся древовидных структур данных. Если не принимать определенных мер, то эффективность выполнения операций с двоичным деревом поиска может значительно снизиться с увеличением числа его узлов. Во избежание подобных явлений используется балансировка, а деревья называются самобалансирующимися. Это означает, что при выполнении операций, таких как поиск, добавление и удаление элемента, помимо собственно полезного действия производятся преобразования структуры дерева, сохраняющие свойство поиска (ключи узлов левого поддеревья меньше ключа корня этого поддерева, ключи узлов правого поддерева больше ключа корня этого поддерева), но приводящие дерево к сбалансированному виду. Для различных деревьев данные операции различны, как различны и критерии сбалансированности.

Чаще всего используется балансировка по высоте, под высотой при этом понимается расстояние от корня до листа. Механизмы, обеспечивающие сбалансированность по высоте, реализованы в АВЛ- и красно-черных деревьях.

АВЛ-деревья являются первыми широко известными самобалансирующимися древовидными структурами данных [1]. АВЛ-деревья поддерживают строгий баланс, основывающийся на высоте поддеревьев. Инвариант для узла АВЛ-дерева:

$$|H_{\text{left}} - H_{\text{right}}| \leq 1, \quad (2)$$

где H_{left} , H_{right} — высота соответственно левого и правого поддеревьев узла.

В каждом узле дерева хранится дополнительная информация — его фактор баланса, который является целым числом в диапазоне $[-1; 1]$ и представляет собой разность высоты левого и правого поддеревьев. В случае нарушения инварианта в каком-то узле выполняются вращения.

К достоинствам АВЛ-деревьев относится гарантированная $O(\log n)$ сложность операций в худшем случае, к недостаткам — довольно большое количество вращений, необходимость которых проистекает из жесткости условия сбалансированности [2].

В *красно-черных деревьях* узлы содержат бит, определяющий их „цвет“, который, в свою очередь, накладывает ряд ограничений на структуру дерева. При нарушении этих ограничений осуществляются вращения и „перекрашивания“ узлов [3].

К достоинствам красно-черных деревьев относится гарантированная $O(\log n)$ сложность операций в худшем случае, а также малое количество вращений при их выполнении [2].

Splay-деревья (в русскоязычной литературе также называемые расширяющимися или косыми) не являются балансируемыми по высоте, в отличие от красно-черных и АВЛ-деревьев [4].

Идея, лежащая в основе построения splay-деревьев, была взята из эвристики перехода на передний план (move-to-front) в самоорганизующихся списках: каждый раз узел дерева, к которому выполняется обращение, становится корнем. Для этого используется специальная операция splay.

Эта структура данных интересна тем, что разработана для приложений, в которых важен быстрый доступ к часто используемым элементам, поскольку они будут часто подвергаться операции splay и вследствие этого с высокой вероятностью располагаться ближе к корню.

К достоинствам splay-деревьев можно отнести отсутствие накладных расходов по памяти (в узлах дерева не хранятся дополнительных полей) и хорошую производительность, когда доступ к некоторым узлам выполняется значительно чаще, чем к остальным, что является важным преимуществом в задаче контекстного моделирования. К недостаткам относится амортизированная $O(\log n)$ сложность операций (отдельные операции имеют сложность $\Omega(n)$), а также большое количество выполняемых вращений при каждом обращении к структуре данных [2].

В исследованиях splay-деревья показывают хорошую производительность при доступе к данным, имеющим последовательный или кластеризованный характер [5].

Scaregoat-деревья, в отличие от красно-черных и АВЛ-деревьев, опираются на весовой баланс поддеревьев, причем под весом поддерева понимается число узлов в нем [6].

Инвариант scaregoat-дерева имеет вид:

$$S_{\text{left}} \leq \alpha S_{\text{total}}, \quad S_{\text{right}} \leq \alpha S_{\text{total}}, \quad (3)$$

где α — фактор баланса в диапазоне $[0,5; 1]$, позволяющий настроить строгость балансировки дерева: $\alpha = 0,5$ соответствует полному бинарному дереву, $\alpha = 1$ допускает вырождение в линейный список; S_{left} — число узлов поддерева с корнем в левом потомке текущего узла;

S_{right} — число узлов поддереза с корнем в правом потомке текущего узла; S_{total} — число узлов поддереза с корнем в текущем узле.

Интересно, что при нарушении инварианта выполняются не вращения, а полное перестроение дерева.

Достоинством splay-деревьев является поддержка отложенных операций удаления узлов и балансировки, что снижает накладные расходы при работе с деревом.

К недостаткам относится амортизированная $O(\log n)$ сложность операций — отдельные операции имеют сложность $\Omega(n)$ [2].

Классические декартовы деревья не являются сбалансированными в строгом смысле слова, поскольку их структура зависит не от данных в элементах и не от порядка поступления этих данных на вход, а от случайно генерируемого и назначаемого каждому элементу приоритета, для которого дерево выполняет требование двоичной кучи (приоритет родителя должен быть больше приоритета потомков). Приоритет узла в течение жизни структуры данных не изменяется, вращения не используются, вместо них применяются операции разрезания и склеивания [7].

Преимуществом такой структуры данных можно назвать высокую вероятность $O(\log n)$ сложности операций с ней.

Представленные структуры данных широко используются, однако не вполне отвечают требованиям поставленной задачи. Декартовы, красно-черные, АВЛ- и splay-деревья со случайными весами предназначены для поддержания близкой к оптимальной структуры, выполняя балансировку по высоте, но при этом игнорируя востребованность элементов.

Splay-деревья спроектированы так, чтобы учитывать востребованность элементов и ускорять доступ к наиболее востребованным, но обладают только амортизированной логарифмической сложностью, что накладывает ограничения на их применимость в ряде задач.

Описание предлагаемой структуры данных. Как уже упоминалось, предлагаемая структура данных предназначена для накопления статистики порожденных символов дискретного источника информации с целью создания его модели. Структура данных оперирует приоритетами узлов, связанных с вероятностью порождения соответствующих символов, и стремится минимизировать время доступа к узлам с высоким приоритетом.

В дальнейшем будем полагать, что приоритет символа прямо пропорционален оценке вероятности его порождения. Поскольку оценка априорна, следует говорить не о приоритете символа, а об оценке приоритета.

Для выполнения поставленного условия каждый элемент i рассматриваемой структуры должен хранить полезную информацию, а также быть аннотированным некоторым значением X_i , по которому можно оценить его приоритет: $P_i = f(X_i)$.

Аннотирование элемента i количеством его появлений в этом контексте (т.е. когда производился поиск элемента i в структуре) обеспечивает простоту вычисления и модификации данного элемента.

В принципе, на область значений оценки приоритета не накладывается каких-либо ограничений, поэтому для простоты можно положить, что $P_i = X_i$.

Особым случаем является ситуация, когда $P_i = 0$, т.е. символ ни разу не был встречен в текущем состоянии до этого момента. Данная проблема в контекстном моделировании известна как „проблема нулевой вероятности“ [8]. В описываемой структуре в такой ситуации будут выполняться добавление элемента и инициализация оценки его приоритета значением 1.

Для простоты назовем оценку приоритета узла весом. Это позволит ввести понятие меры веса поддереза и балансировки по весу. Исходя из принятых ранее допущений вес узла, число обращений к узлу и оценка приоритета узла — суть одно и то же число, и именно им аннотирован узел.

Распространенной практикой построения структур данных является кэширование мер поддеревьев, в частности, при реализации структуры данных *rope* (в русскоязычной литературе — „строп“, „веревка“ или „корд“), применяющейся для хранения и обработки операций со строками [9]. Показано, что кэшировать можно результат вычисления любой операции, если она и тип данных, к которому она применяется, образуют моноид — полугруппу с нейтральным элементом [10]. В настоящей работе моноид составляет тройка $\langle +, \text{вес элемента, нулевой вес} \rangle$.

Балансировка предлагаемой структуры данных по весу производится с использованием кэширования суммарного веса поддерева в его корне. Если точнее, то кэшируется суммарный вес левого поддерева, т.е. поддерева с корнем в виде левого потомка текущего узла, суммарный вес правого поддерева вычисляется как

$$P_{\text{right}} = P_{\text{total}} - P_{\text{left}} - P_{\text{root}}, \quad (4)$$


где P_{total} — вес поддерева с корнем в текущем узле; P_{left} — вес поддерева с корнем в левом потомке текущего узла; P_{right} — вес поддерева с корнем в правом потомке текущего узла; P_{root} — вес текущего узла.

Общий вес поддерева P_{total} запоминается в процессе спуска по дереву уровнем выше.

Также в процессе спуска инкрементируются хранящиеся в узлах меры P_{left} , если поиск продолжается в левом поддереве.

Для балансировки дерева предлагается использовать вращения, схожие по механизму с теми, что используются в структурах данных, балансируемых по высоте, однако использующие другие инварианты.

На рисунке приводится схема правого вращения (*a* — структура дерева до вращения; *b* — после вращения). При этом кругами обозначены узлы дерева, а треугольниками — левые или правые поддеревья (соответственно направлению острого угла треугольника). Каждый элемент дерева подписан буквой латинского алфавита, которая отражает лексикографический порядок, установленный в двоичном дереве поиска.



Инвариант для правого вращения имеет вид:

$$|P_a + P_b + P_c - P_e| \leq |P_c + P_d + P_e - P_a|, \quad (5)$$

где P_i — вес узла или поддерева i . Смысл этого инварианта заключается в том, что разность суммарных весов левого и правого поддеревьев до потенциального правого вращения должна быть меньше, чем после преобразования. Если инвариант нарушается, это провоцирует правое вращение, которое восстанавливает инвариант. Инвариант левого вращения и его схема зеркально симметричны инварианту правого вращения (5) и его схеме.

При вращении переназначаются кэшированные в узлах меры суммарных весов.

Идея балансировки заключается в том, чтобы максимально равномерно распределить между правым и левым поддеревом каждого узла операции поиска элементов.

Интересным свойством предлагаемой структуры данных является то, что кэшированные веса являются не только средством для балансировки дерева по востребованности узлов, но и

данными для расчета вероятностного интервала символа, используемого для кодирования дискретного источника информации.

Предлагаемая структура данных имеет ряд особенностей, которые необходимо учитывать в различных сценариях ее поведения:

— в задачах общего типа она уступает остальным структурам данных в объеме накладных расходов по памяти, поскольку каждый узел хранит дополнительно два поля: собственный вес и вес своего левого поддерева;

— представляют существенную трудность и пока не реализованы операции склейки деревьев, разделения дерева на два, а также удаления узлов и множественные операции с узлами. Тем не менее, в задаче моделирования дискретных источников информации эти операции не применяются, значит, их реализация является второстепенной задачей;

— не учитывается возможная локальность поведения источника информации (ситуация, когда вероятностное распределение порождаемых символов лишь несущественно меняется на коротком отрезке времени, после чего происходит его значительное изменение). В отличие от *splay*-дерева, предлагаемая структура данных с трудом приспосабливается к изменениям характеристик источника. Впрочем, в контекстном моделировании применяются механизмы, нивелирующие эту проблему.

Заключение. Традиционно применяемые балансируемые древовидные структуры данных не вполне подходят под специфику задачи моделирования дискретного источника информации.

В предложенной структуре учитывается, что различные ее элементы неравнозначны по востребованности и содержат механизмы минимизации времени доступа к наиболее востребованным элементам.

СПИСОК ЛИТЕРАТУРЫ

1. Адельсон-Вельский Г. М., Ландис Е. М. Один алгоритм организации информации // Докл. АН СССР. 1962. Т. 146, № 2. С. 263—266.
2. Кормен Т. Х., Лейзерсон Ч. Е., Ривест Р. Л., Штайн К. Алгоритмы: построение и анализ. М.: Вильямс, 2013. 1328 с.
3. Guibas L. J., Sedgewick R. A dichromatic framework for balanced trees // Proc. of the 19th Annual Symp. on Foundations of Computer Science (SFCS 1978). Ann Arbor, MI, USA. 1978. P. 8—21.
4. Sleator D., Tarjan R. E. Self-Adjusting Binary Search Trees // J. of the Association for Computing Machinery. 1985. Vol. 32, N 3. P. 652—686.
5. Pfaff B. Performance Analysis of BSTs in System Software // ACM SIGMETRICS Performance Evaluation Review. 2004. Vol. 32, is. 1. P. 410—411.
6. Galperin I., Rivest R. Scapegoat trees // Proc. of the Fourth Annual ACM-SIAM Symp. on Discrete algorithms (SODA '93). Society for Industrial and Applied Mathematics, USA, 1993. P. 165—174.
7. Seidel R., Aragon C. R. Randomized search trees // Algorithmica. 1996. Vol. 16. P. 464—497.
8. Cleary J., Teahan W. Experiments on the zero frequency problem // Proc. of the DCC '95 Data Compression Conf. 1995. P. 480.
9. Boehm H., Atkinson R., Plass M. Ropes: an Alternative to Strings // Software—Practice and Experience. 1995. Vol. 25, N 12. P. 1315—1330.
10. Hinze R., Paterson R. Finger Trees: A Simple General-purpose Data Structure // J. of Functional Programming. 2006. Vol. 16, N 2. P. 197—217.

Сведения об авторе

Алексей Владимирович Аксенов

— Санкт-Петербургский государственный университет аэрокосмического приборостроения, кафедра вычислительных систем и сетей; старший преподаватель; E-mail: aksenov@guap.ru

Поступила в редакцию 04.12.23; одобрена после рецензирования 14.12.23; принята к публикации 08.02.24.

REFERENCES

1. Adel'son-Vel'skii G.M., Landis E.M. *Doklady Akademii Nauk SSSR*, 1962, no. 2(146), pp. 263–266. (in Russ.)
2. Cormen Th.H., Leiserson Ch.E., Rivest R.L., Stein C. *Introduction to Algorithms*, MIT Press, 2009.
3. Guibas L.J., Sedgewick R. *Proceedings of the 19th Annual Symposium on Foundations of Computer Science (SFCS 1978)*, Ann Arbor, MI, USA, 1978, pp. 8–21.
4. Sleator D., Tarjan R.E. *Journal of the Association for Computing Machinery*, 1985, no. 3(32), pp. 652–686.
5. Pfaff B. *ACM SIGMETRICS Performance Evaluation Review*, 2004, no. 1(32), pp. 410–411.
6. Galperin I., Rivest R. *Proc. of the Fourth Annual ACM-SIAM Symp. on Discrete algorithms (SODA '93)*, Society for Industrial and Applied Mathematics, USA, 1993, pp. 165–174.
7. Seidel R., Aragon C.R. *Algorithmica*, 1996, vol. 16, pp. 464–497.
8. Cleary J., Teahan W. *Proceedings of the DCC '95 Data Compression Conference*, 1995, p. 480.
9. Boehm H., Atkinson R., Plass M. *Software—Practice and Experience*, 1995, no. 12(25), pp. 1315–1330.
10. Hinze R., Paterson R. *Journal of Functional Programming*, 2006, no. 2(16), pp. 197–217.

Data on author

Aleksey V. Aksenov — St. Petersburg State University of Aerospace Instrumentation, Department of Computing Systems and Networks; Senior Lecturer; E-mail: aksenov@guap.ru

Received 04.12.23; approved after reviewing 14.12.23; accepted for publication 08.02.24.

МЕТОДЫ И ПРИБОРЫ ДЛЯ АНАЛИЗА И КОНТРОЛЯ МАТЕРИАЛОВ, ИЗДЕЛИЙ, ВЕЩЕСТВ И ПРИРОДНОЙ СРЕДЫ

METHODS AND INSTRUMENTS FOR ANALYSIS AND MONITORING OF THE NATURAL ENVIRONMENT, SUBSTANCES, MATERIALS AND PRODUCTS

УДК 528.88:504.064:551.501.89
DOI: 10.17586/0021-3454-2024-67-4-359-367

ИССЛЕДОВАНИЕ ИЗМЕНЧИВОСТИ ПРИРОДНО-ТЕРРИТОРИАЛЬНЫХ КОМПЛЕКСОВ ТАЗОВСКОГО ПОЛУОСТРОВА НА ОСНОВЕ ДАННЫХ МНОГОСПЕКТРАЛЬНОЙ И РАДИОЛОКАЦИОННОЙ КОСМИЧЕСКОЙ СЪЕМКИ

Е. Ф. ЧИЧКОВА*, В. А. ХАМЕДОВ, С. А. РОГАЧЕВ

Санкт-Петербургский государственный университет аэрокосмического приборостроения

Санкт-Петербург, Россия

**efchichkova@yandex.ru*

Аннотация. Рассмотрены особенности изучения внутрисезонной изменчивости природно-территориальных комплексов (ПТК) в Арктической зоне Российской Федерации (АЗРФ) средствами многоспектрального и радиолокационного космического мониторинга. Из-за особых условий освещенности и высокой облачности возможности космических аппаратов (КА) с оптическими приборами на борту ограничены для съемки территорий АЗРФ. Для обеспечения космического мониторинга природных территорий АЗРФ необходима разработка методик с использованием радиолокационных методов, не зависящих от условий съемки. На примере отдельно взятого региона АЗРФ — Тазовского полуострова — проанализирована внутрисезонная изменчивость наиболее характерных типов ПТК (кустарничко-лишайниковые тундры; сфагновые болота; ивняки травяные; песчаные отмели и антропогенные объекты). Методы исследования включают интерферометрическую обработку исходных радиолокационных данных SAR KA Sentinel-1B и обработку данных KA Sentinel-2A, 2B по алгоритмам классификации и расчета спектральных вегетационных индексов. На основе результатов классификации поверхностей полигона Тазовского полуострова, проведенной по многоспектральной космической информации, выбраны четыре опорных участка ПТК. Анализ стабильности и изменчивости поверхностей на выбранных участках полигона проведен на основе рассчитанных рядов интерферометрической когерентности для каждого типа ПТК в бесснежный период 2021 года. Для интерпретации полученных результатов использованы статистически обработанные ряды метеорологических наблюдений за температурой воздуха и осадками и данные вегетационных индексов. Результаты исследования могут быть наиболее востребованными в производственно-экологическом мониторинге нефтегазовой отрасли и охране окружающей среды с целью соблюдения технологической безопасности и выявления степени антропогенной нарушенности территорий АЗРФ.

Ключевые слова: космический мониторинг, арктическая зона, многоспектральные данные, радиолокационные данные, интерферометрическая когерентность, изменчивость, природно-территориальный комплекс

Благодарности: авторский коллектив выражает искреннюю благодарность за профессиональные консультации при подготовке данной публикации начальнику Гидрометцентра ФГБУ „Северо-Западное УГМС“ А. М. Колесову и кандидату биологических наук, доценту РГПУ им. А. И. Герцена Н. В. Кобелевой. Работа выполнялась в рамках темы Госзадания № FSRF-2023-0003.

Ссылка для цитирования: Чичкова Е. Ф., Хамедов В. А., Рогачев С. А. Исследование изменчивости природно-территориальных комплексов Тазовского полуострова на основе данных многоспектральной и радиолокационной космической съемки // Изв. вузов. Приборостроение. 2024. Т. 67, № 4. С. 359—367. DOI: 10.17586/0021-3454-2024-67-4-359-367.

STUDY OF THE VARIABILITY OF NATURAL-TERRITORIAL COMPLEXES OF THE TAZ PENINSULA
BASED ON MULTISPECTRAL AND RADAR SPACE SURVEY DATA

E. F. Chichkova*, V. A. Khamedov, S. A. Rogachev

St. Petersburg State University of Aerospace Instrumentation, St. Petersburg, Russia
efchichkova@yandex.ru

Abstract. The features of studying intraseasonal variability of natural-territorial complexes in the Arctic zone of the Russian Federation using multispectral and radar space monitoring are considered. Due to special lighting conditions and high cloudiness, the capabilities of spacecraft with optical instruments on board for surveying the territories of the Russian Arctic, are limited. To ensure space monitoring of natural territories of the Russian Arctic, it is necessary to develop techniques using radar methods that do not depend on shooting conditions. Using the example of a single region of the Russian Arctic – the Taz Peninsula – the intraseasonal variability of the most characteristic types of natural-territorial complexes (shrub-lichen tundra; sphagnum bogs; grass willows; sandbanks and anthropogenic objects) is analyzed. Research methods include interferometric processing of original SAR radar data from the Sentinel-1B spacecraft and processing of data from the Sentinel-2A, 2B spacecrafts using algorithms for classification and calculation of spectral vegetation indices. Based on the results of classification of the surfaces of the Taz peninsula test site, carried out using multispectral space information, four reference areas of the natural-territorial complex were selected. An analysis of the stability and variability of surfaces in selected areas of the test site was carried out on the basis of calculated series of interferometric coherence for each type of natural-territorial complex in the snow-free period of 2021. To interpret the results obtained, statistically processed series of meteorological observations of air temperature and precipitation and data from vegetation indices were used. The results of the study may be most in demand in industrial and environmental monitoring of the oil and gas industry and environmental protection in order to maintain technosphere safety and identify the degree of anthropogenic disturbance in the territories of the Russian Arctic.

Keywords: space monitoring, Arctic zone, multispectral data, radar data, interferometric coherence, variability, natural-territorial complex

Acknowledgments: The team of authors expresses sincere gratitude for the professional advice in the preparation of this publication to the head of the Hydrometeorological Center of the Federal State Budgetary Institution “North-West UGMS” A. M. Kolesov and to Candidate of Biological Sciences, Associate Professor of the A. I. Herzen Russian State Pedagogical University N. V. Kobeleva. The work was carried out within the framework of the theme of State Assignment No. FSRF-2023-0003.

For citation: Chichkova E. F., Khamedov V. A., Rogachev S. A. Study of the variability of natural-territorial complexes of the Taz peninsula based on multispectral and radar space survey data. *Journal of Instrument Engineering*. 2024. Vol. 67, N 4. P. 359—367 (in Russian). DOI: 10.17586/0021-3454-2024-67-4-359-367.

Введение. Любой природно-территориальный комплекс (ПТК) Арктики является хрупкой и уникальной системой, которая неизбежно изменяется согласно естественным закономерностям, а также вследствие возрастающей антропогенной нагрузки на регион. Задачи мониторинга ПТК Арктической зоны Российской Федерации (АЗРФ) в целом следующие: определение изменений компонентов окружающей среды, классификация изменений, выяснение их масштабов и определение допустимости изменений [1—4].

Современный подход к космическому мониторингу заключается в разработке методов и технологических решений, учитывающих значительные трудо-, время-, ресурсоемкость проведения контроля среды и позволяющих повышать его эффективность [5, 6]. В последнее время в исследованиях возможностей проведения мониторинга северных регионов РФ помимо многоспектрального зондирования все большее значение уделяется радиолокационным спутниковым данным [7—9].

Использование данных различных космических систем радиолокационного наблюдения (Radarsat-1,-2, ENVISAT/ASAR, ERS-1,-2, TerraSAR-X и др.) для исследований и самого мониторинга территорий долгое время было практически недоступно из-за высокой стоимости данных. С 2014 года после запуска КА Sentinel-1A Европейским космическим агентством (ESA) открыт бесплатный доступ к архиву снимков на портале программы „Коперник“^{**}.

* Open Access Hub, <https://scihub.copernicus.eu>.

Для настоящей работы первостепенное значение имеет опыт исследования на основе радиолокационных данных тундровых территорий АЗРФ [10—13]. Понятие когерентности как результата интерферометрической обработки радиолокационных данных в настоящей работе характеризует стабильность и изменчивость в определенном временном интервале подстилающей поверхности Земли. В работе [12] значения интерферометрической когерентности используются для анализа тундровых территорий АЗРФ на примере острова Котельный. Особая результативность при проведении мониторинга различных ПТК АЗРФ свойственна совместному использованию многоспектральной и радиолокационной съемки [12, 13]. Для исследования изменчивости подстилающей поверхности был выбран полигон на Тазовском полуострове. Временной интервал для космического мониторинга — бесснежный период 2021 года.

Описание полигона исследования. Выбор полигона для исследования ПТК на территории Тазовского полуострова обусловлен географическим расположением с типичными для АЗРФ климатическими и ландшафтными характеристиками и наличием техногенных объектов Ямбургского месторождения природного газа. Полигон расположен в центральной части полуострова Тазовский (выделено на рис. 1).

Поверхность Тазовского полуострова, особенно прибрежных террас, расчленена густой сетью оврагов, логов, ложбин и мелких речных долин. Поймы рек нередко представляют собой песчаные равнины, не закрепленные растительностью; многие поймы сильно заболочены и изрезаны многочисленными старицами и протоками. Сплошное распространение многолетней мерзлоты и ее поверхностное залегание приводят к повсеместному развитию криогенных и термокарстовых форм рельефа [14]. Следствием разнообразия форм микрорельефа и микроклиматических условий является растительный покров с ярко выраженным неоднородным горизонтальным сложением: бугорковатые, полигональные, пятнистые тундры, полигональные болота, лиственничные редколесья [15].

На формирование климата влияют многолетняя мерзлота, близость холодного Карского моря, обилие болот, озер и рек. Долгая зима, короткое прохладное лето, сильные ветра, незначительный снежный покров — все это способствует промерзанию почвы на большую глубину. Климатические условия 2021 года характеризовались аномально теплыми весенним и летним, а также аномально холодным зимним сезонами [16]. Наиболее значительный дефицит осадков в районе Обской губы наблюдался в январе—феврале (40—80 % нормы для севера страны), поэтому здесь были получены значительные отрицательные аномалии запаса воды в снеге.




Рис. 1

Данные и методы исследования. При выполнении исследований использованы данные с космических аппаратов Sentinel-1B и Sentinel-2A, 2B ESA. Обработка данных проводилась с помощью специализированных программ Sentinel Application Platform (SNAP) ESA и ERDAS Imagine.

На первом этапе космического мониторинга полигона использовались данные мультиспектральной камеры MSI KA Sentinel-2 A, B в трех каналах видимого (0,490; 0,560; 0,665 мкм) и в одном ближнем инфракрасном (0,842 мкм) диапазоне спектра. Успешная совместная работа обоих спутников обеспечивает систематическое покрытие космическими снимками территории между 84° с.ш. и 56° ю.ш. с пространственным разрешением 10 м в надире. Исходные данные KA Sentinel-2 размещены в открытом доступе.

В результате отбора в бесснежный период 2021 года при малооблачной атмосфере были получены многоспектральные спутниковые данные за 17.06.2021, 15.07.2021, 05.09.2021. Пример снимка KA Sentinel-2 для полигона приведен на рис. 1. Тематическая обработка многоспектральных данных заключалась в классификации подстилающих поверхностей, идентификации типов выбранных классов и в построении индексов вегетации. Для классификации выбрано растровое изображение космической съемки KA Sentinel-2 за 15.07.2021. Был использован метод неуправляемой классификации ISODATA — итерационная самоорганизующаяся методика анализа данных (Iterative Self-Organizing Data Analysis Technique).

В качестве объекта при использовании спектральных индексов чаще всего выступает растительность. Наиболее используемый индекс NDVI — нормализованный разностный индекс растительности (Normalized Difference Vegetation Index) — впервые был описан В. J. Rouse в 1974 г. [17]. NDVI рассчитывается как соотношение разности значений радиационной яркости ближнего инфракрасного и красного каналов к их сумме. Индекс может принимать значения от –1 до 1. Для растительности индекс NDVI принимает положительные значения, и чем больше зеленой фитомассы, тем он выше. На значение индекса влияет также видовой состав растительности, ее сомкнутость, состояние, экспозиция и угол наклона поверхности, цвет почвы под разреженной растительностью. Индекс умеренно чувствителен к изменениям почвенного фона, кроме случаев, когда густота растительного покрова ниже 30 %. NDVI был рассчитан для всего набора данных KA Sentinel-2.

На втором этапе космического мониторинга территории полигона Тазовского полуострова для получения информации об изменчивости наблюдаемой поверхности в работе использовались комплексные радиолокационные данные (продукт SLC уровня обработки Level-1), включающие амплитуду и фазу сигнала. Радиолокационная станция с синтезированной апертурой Synthetic Aperture Radar (SAR) на борту KA Sentinel-1B обеспечивает всепогодную съемку в С-диапазоне (длина волны 6 см). При помощи программного обеспечения SNAP выполнен автоматизированный расчет когерентности для десяти интерферометрических пар изображений, полученных с периодичностью в двенадцать суток в бесснежный период с 16.06.2021 по 02.10.2021. В итоге получены значения интерферометрической когерентности в согласованной вертикальной поляризации VV для выбранных типов подстилающей поверхности.

Для интерпретации результатов при дешифрировании космических снимков проанализированы погодные условия полигона в бесснежный период 2021 года по данным наблюдений трех станций 23058 Антипаюта (69,15 с.ш. и 77,00 в.д.), 23256 Тазовский (67,47 с.ш. и 78,73 в.д.) и 23242 Новый порт (67,68 с.ш. и 72,87 в.д.). Использовались следующие метеоданные: температура воздуха и количество осадков. Данные по трехчасовым срокам наблюдений осреднены за метеорологические сутки с 21:00 предыдущей даты до 18:00 текущей.

Результаты исследования. Использование данных оптических и радиолокационных космических снимков в совокупности повышает оперативность мониторинга ПТК в любой географической зоне. Это особенно важно для территории АЗРФ, где многоспектральная

спутниковая съемка может дать опорную информацию приблизительно 1—5 раз в год из-за сильной облачности.

Анализ результатов проведенного спутникового мониторинга по данным различных космических систем показал, что территория полигона на Тазовском полуострове обладает значительной внутрисезонной изменчивостью (среднестатистический коэффициент интерферометрической когерентности по радиолокационной съемке не превышает 0,4 единиц). На рис. 2 представлен фрагмент растрового изображения результатов классификации по данным 15.07.2021 с КА Sentinel-2 с обозначенными опорными участками для исследования изменчивости типов ПТК. Выбраны наиболее значимые для данного полигона четыре типа ПТК: кустарничко-лишайниковые тундры (68,108712° с.ш. и 76,228135° в.д.); сфагновые болота (68,095094° с.ш., 76,321931° в.д.); ивняки травяные (68,1013062° с.ш., 76,234993° в.д.); песчаные отмели (68,093949° с.ш., 76,300009° в.д.) и антропогенные объекты. Другие виды тундровых сообществ объединены в отдельный тип (рис. 2).




Рис. 2

Индекс вегетации был рассчитан для статистически значимых наборов точек, выбранных по всему полигону Тазовского полуострова. В таблице представлены статистические характеристики NDVI (среднее значение/среднеквадратическое отклонение) для классов ПТК с размером выборки набора данных n .

Дата съемки КА Sentinel-2	Песчаные отмели и антропогенные объекты ($n = 32$)	Кустарничково-лишайниковые тундры ($n = 42$)	Сфагновые болота ($n = 37$)	Ивняки травяные ($n = 39$)
17.06.2021	0,059/0,016	0,154/0,024	0,261/0,043	0,185/0,019
15.07.2021	0,076/0,021	0,206/0,034	0,326/0,039	0,425/0,039
05.09.2021	0,067/0,024	0,156/0,020	0,268/0,033	0,269/0,024

На рис. 3, а построены график внутрисезонной изменчивости средней температуры T и гистограмма суммарного количества осадков R за 12-дневные периоды для территории полигона. На рис. 3, б для четырех выбранных участков ПТК представлены графики интерферометрической когерентности K , построенные на основе обработки радиолокационных данных Sentinel-1B, и гистограмма средних значений вегетационного индекса NDVI из таблицы.




Рис. 3

Значения когерентности сопоставлены с результатами расчетов по данным метеорологических станций (температура воздуха, количество осадков), а также значениями вегетационных индексов, полученных по спутниковым данным в оптическом диапазоне. Ввести в рассмотрение характеристику скорости ветра оказалось невозможно из-за частой повторяемости сильного ветра (более 10 м/с).

Комплексный анализ временных рядов рассчитанных характеристик за бесснежный период 2021 года позволяет сделать общие выводы об изменчивости выбранных участков ПТК (рис. 3):

1) интерферометрическая когерентность на исследуемых участках варьирует в пределах $K = 0,11—0,71$;

2) наиболее стабильна поверхность сфагновых болот и кустарничко-лишайниковых тундр;

3) максимальная изменчивость поверхностей кустарничко-лишайниковых тундр с $K = 0,21$ соответствует периоду активной вегетации в конце июля при выпадении значительной суммы осадков и высокой температуре ($T = 14^\circ \text{C}$);

4) участок травяных ивняков, расположенный на хасырее, обладает наибольшей изменчивостью из всех ПТК при $K = 0,12—0,40$ и достигает максимальной устойчивости лишь в первой половине июля, в период максимальной вегетации травянистых растений;

5) для участка на песчаной отмели отмечается устойчивость покрова с конца августа до середины сентября, вероятно, вследствие большого для этого региона количества осадков ($R = 40$ мм за 12 дней);

6) при появлении осадков в виде снега (рис. 3, б, 02.10.2021) состояние поверхностей всех типов ПТК нестабильно;

7) характеристики вегетационных индексов, как показатели изменчивости подстилающих поверхностей на полигоне Тазовского полуострова, имеют небольшой разброс для каждого выбранного типа ПТК с коэффициентом вариации 0,07—0,15;

8) самый высокий вегетационный индекс на полигоне Тазовского полуострова имеет ПТК „ивняки травяные“ (значение 0,4 в июле).

Заключение. По результатам космического мониторинга, проведенного на территории тестового полигона Тазовского полуострова, выявлены особенности динамики состояния ПТК для преобладающих типов подстилающих поверхностей в бесснежный период 2021 года. Совместное использование данных многоспектральной и радиолокационной космической съемки территории полигона позволяет отслеживать временную и пространственную изменчивость ПТК АЗРФ. Совместный статистический анализ данных о погодных условиях и дополнительных источников информации о характере местности позволяет интерпретировать результаты космического мониторинга. Вместе с этим для изучения взаимосвязи результатов, полученных с использованием данных многоспектральной и радиолокационной космической съемки, требуются дополнительные исследования.

СПИСОК ЛИТЕРАТУРЫ

1. Кобелева Н. В. Крупномасштабное эколого-фитоценотическое картографирование на основе аэроснимков и ГИС-технологий (на примере центральной части Тазовского полуострова) // Изв. Самарского научного центра Российской академии наук. 2012. Т. 14, № 1-6. С. 1607—1617.
2. Московченко Д. В., Арефьев С. П., Глазунов В. А., Тигеев А. А. Изменение состояния растительности и геоэкологических условий Тазовского полуострова (восточная часть) за период 1988—2016 гг. // Криосфера Земли. 2017. Т. 21, № 6. С. 3—13. DOI: 10.21782/KZ1560-7496-2017-6(3-13).
3. Московченко Д. В., Глазунов В. А., Тигеев А. А. Исследование динамики растительного покрова восточной части Тазовского полуострова // Экологический мониторинг и биоразнообразие. 2016. № 1(11). С. 91—96.
4. Арефьев С. П. Реакция деревьев и кустарников восточной части Тазовского полуострова на потепление климата // Экологический мониторинг и биоразнообразие. 2016. № 1(11). С. 5—9.
5. Минаков Е. П., Чичкова Е. Ф. Мониторинг чрезвычайных ситуаций с использованием дистанционного зондирования Земли // Изв. вузов. Приборостроение. 2009. Т. 52, № 4. С. 23—27.
6. Чичкова Е. Ф., Кочин Д. А., Рогачев С. А. Информационно-аналитический сервис и технологии мониторинга потенциально опасных зон по данным спутникового многоспектрального зондирования // Космические аппараты и технологии. 2023. Т. 7, № 2. С. 132—141. DOI: 10.26732/j.st.2023.2.06.
7. Мазуров Б. Т., Аврунев Е. И., Хамедов В. А. Оперативный мониторинг лесных земель северных регионов на основе использования оптических и радарных космических снимков // Современные проблемы дистанционного зондирования Земли из космоса. 2017. Т. 14, № 4. С. 103—111.
8. Мышляков С. Г. Возможности радарных снимков Sentinel-1 для решения задач сельского хозяйства // Геоматика. 2016. № 2. С. 16—24.
9. Копылов В. Н., Полищук Ю. М., Хамедов В. А. Синтез оптических и радиолокационных космических снимков при решении задачи оперативного обнаружения лесных гарей // Гео-Сибирь. 2007. Т. 3. С. 157—162.
10. Балдина Е. А., Трошко К. А., Николаев Н. Р. Радиолокационные данные Sentinel-1 и возможности их обработки для дешифрирования форм рельефа острова Котельный // Изв. вузов. Геодезия и аэрофотосъемка. 2016. № 3. С. 78—85.
11. Antonova S., Käab A., Heim B., Langer M., Boike J. Spatio-temporal variability of X band radar backscatter and coherence over the Lena River Delta, Siberia // Remote Sensing of Environment. 2016. Vol. 182. P. 169—191. DOI:10.1016/j.rse.2016.05.003.
12. Трошко К. А., Балдина Е. А., Мартыанов А. С., Денисов П. В. Географическая интерпретация временных изменений когерентности по радиолокационным данным Sentinel-1 (на примере острова Котельный) // Матер. 17-й Всерос. открытой конф. „Современные проблемы дистанционного зондирования Земли из космоса“. М., 11—15 ноября 2019 г. М.: Ин-т космических исследований РАН, 2019. С. 461.

13. Regmi P., Grosse G., Jones M. C., Jones B. M., Walter A. K. Characterizing post-drainage succession in thermokarst lake basins on the Seward Peninsula, Alaska with TerraSAR-X backscatter and Landsat-based NDVI data // *Remote Sens.* 2012. N 4. P. 3741—3765. DOI:10.3390/rs4123741.
14. Строительство поглощающих скважин № 1п, 2п, 3п месторождения Каменномысское-море. Оценка воздействия на окружающую среду. М., 2022. 274 с. [Электронный ресурс]: <https://seaprojects.gazprom.ru/d/textpage/9b/155/ovos_1p-2p-3p.pdf>.
15. Валеева Э. И., Московченко Д. В. Зональные особенности растительного покрова Тазовского полуострова и его техногенная трансформация // *Вестн. экологии, лесоведения и ландшафтоведения.* 2008. № 9. С. 174—191.
16. Доклад об особенностях климата на территории Российской Федерации за 2021 год. М.: Росгидромет, 2022. 104 с. [Электронный ресурс]: <<https://www.meteorf.gov.ru/images/news/20220324/4/Doklad.pdf>>.
17. Rouse J. W., Haas R. H., Schell J. A. et al. Monitoring the vernal advancements and retrogradation of natural vegetation // NASA/GSFC, Final Report. Greenbelt, MD, USA, 1974. P. 1—137.

Сведения об авторах

- | | |
|---------------------------------------|---|
| Елена Федоровна Чичкова | — канд. геогр. наук; Санкт-Петербургский государственный университет аэрокосмического приборостроения, КосмоИнформ-центр ГУАП; директор ЦКУ; E-mail: efchichkova@yandex.ru |
| Владимир Александрович Хамедов | — канд. техн. наук; Санкт-Петербургский государственный университет аэрокосмического приборостроения, КосмоИнформ-центр ГУАП; вед. науч. сотр. ЦКУ; E-mail: khamedov.vladimir@mail.ru |
| Сергей Александрович Рогачев | — Санкт-Петербургский государственный университет аэрокосмического приборостроения, кафедра компьютерных технологий и программной инженерии; старший преподаватель; E-mail: rogachev.seal@gmail.com |

Поступила в редакцию 04.12.23; одобрена после рецензирования 11.12.23; принята к публикации 08.02.24.

REFERENCES

1. Kobeleva N.V. *Izvestia of Samara Scientific Center of the Russian Academy of Sciences*, 2012, no. 1-6(14), pp. 1607–1617. (in Russ.)
2. Moskovchenko D.V., Arefyev S.P., Glazunov V.A., Tigeev A.A. *Earth's Cryosphere*, 2017, no. 6(21), pp. 3–13, DOI 10.21782/KZ1560-7496-2017-6(3-13). (in Russ.)
3. Moskovchenko D.V., Glazunov V.A., Tigeev A.A. *Environmental monitoring and biodiversity*, 2016, no. 1(11), pp. 91–96. (in Russ.)
4. Arefyev S.P. *Environmental monitoring and biodiversity*, 2016, no. 1(11), pp. 5–9. (in Russ.)
5. Minakov E.P., Chichkova E.F. *Journal of Instrument Engineering*, 2009, no. 4(52), pp. 23–27. (in Russ.)
6. Chichkova E.F., Kochin D.A., Rogachev S.A. *Spacecrafts and Technologies*, 2023, no. 2(7), pp. 132–141, DOI: 10.26732/j.st.2023.2.06. (in Russ.)
7. Mazurov B.T., Avrunev E.I., Khamedov V.A. *Sovremennye problemy dstantsionnogo zondirovaniya Zemli iz kosmosa*, 2017, no. 4(14), pp. 103–111. (in Russ.)
8. Myshlyakov S.G. *Geomatics*, 2016, no. 2, pp. 16–24. (in Russ.)
9. Kopylov V.N., Polishchuk Yu.M., Khamedov V.A. *Geo-Siberia*, 2007, vol. 3, pp. 157–162. (in Russ.)
10. Baldina E., Troshko K., Nikolaev N. *Izvestia vuzov. Geodesy and Aerophotosurveying*, 2016, no. 3, pp. 78–85. (in Russ.)
11. Antonova S., Käb A., Heim B., Langer M., Boike J. *Remote Sensing of Environment*, 2016, vol. 182, pp. 169–191, DOI:10.1016/j.rse.2016.05.003.
12. Troshko K.A., Baldina E.A., Martyanov A.S., Denisov P.V. *Sovremennye problemy dstantsionnogo zondirovaniya Zemli iz kosmosa* (Modern Problems of Remote Sensing of the Earth from Space), Proceedings of the 17th All-Russian open Conf., Moscow, November 11–15, 2019, pp. 461. (in Russ.)
13. Regmi P., Grosse G., Jones M.C., Jones B.M., Walter A.K. *Remote Sens.*, 2012, no. 4, pp. 3741–3765, DOI:10.3390/rs4123741.
14. https://seaprojects.gazprom.ru/d/textpage/9b/155/ovos_1p-2p-3p.pdf. (in Russ.)
15. Valeeva E.I., Moskovchenko D.V. *Bulletin of ecology, forestry and landscape science*, 2008, no. 9, pp. 174–191. (in Russ.)
16. <https://www.meteorf.gov.ru/images/news/20220324/4/Doklad.pdf>. (in Russ.)
17. Rouse J.W., Haas R.H., Schell J.A. et al. NASA/GSFC, Final Report, Greenbelt, MD, USA, 1974, pp. 1–137.

Data on authors

- Elena F. Chichkova** — PhD; St. Petersburg State University of Aerospace Instrumentation, Center of space services "Kosmo-Inform-Center"; Director of the Center;
E-mail: efchichkova@yandex.ru
- Vladimir A. Khamedov** — PhD; St. Petersburg State University of Aerospace Instrumentation, Center of space services "Kosmo-Inform-Center"; Leading Researcher;
E-mail: khamedov.vladimir@mail.ru
- Sergei A. Rogachev** — PhD; St. Petersburg State University of Aerospace Instrumentation, Department of Computer Technologies and Software Engineering; Senior Lecturer;
E-mail: rogachev.seal@gmail.com

Received 04.12.23; approved after reviewing 11.12.23; accepted for publication 08.02.24.

МОДЕЛЬНЫЕ ОЦЕНКИ ПАРАМЕТРОВ ПАССИВНЫХ РАДИОТЕХНИЧЕСКИХ СИСТЕМ МОНИТОРИНГА ГРОЗОВОЙ АКТИВНОСТИ

М. В. ПОСТРЫБАЙЛО, Т. М. ТАТАРНИКОВА*

Санкт-Петербургский государственный университет аэрокосмического приборостроения

Санкт-Петербург, Россия

**tm-tatarn@yandex.ru*

Аннотация. Рассмотрена задача проектирования системы мониторинга грозовой активности на основе датчиков, оценивающих параметры молниевых разрядов путем приема электромагнитного излучения, формируемого при движении электрического заряда по каналу молнии. Показано, что для обеспечения основных характеристик проектируемых систем мониторинга грозовой активности, таких как вероятность обнаружения, точность определения координат и тока молниевых разрядов для выбранной рабочей зоны, может быть использовано математическое моделирование. Предложена модель, позволяющая спроектировать конфигурацию системы, способной обеспечить заданные характеристики посредством получения модельных оценок и их последующего анализа. Созданная модель системы мониторинга грозовой активности применена для оценивания вероятности обнаружения молниевых разрядов экспериментальной сетью, развернутой в Санкт-Петербурге.

Ключевые слова: грозовая активность, молниевый разряд, система мониторинга, чувствительность датчика, напряженность электрического поля, расстояние до молниевых разрядов, вероятность обнаружения

Ссылка для цитирования: Пострыбайло М. В., Татарникова Т. М. Модельные оценки параметров пассивных радиотехнических систем мониторинга грозовой активности // Изв. вузов. Приборостроение. 2024. Т. 67, № 4. С. 368—374. DOI: 10.17586/0021-3454-2024-67-4-368-374.

MODEL ESTIMATES OF PARAMETERS OF PASSIVE RADIO SYSTEMS FOR MONITORING LIGHTNING ACTIVITY

M. V. Postrybaylo, T. M. Tatarnikova*

St. Petersburg State University of Aerospace Instrumentation, St. Petersburg, Russia

**tm-tatarn@yandex.ru*

Abstract. The problem of designing a system for monitoring lightning activity is considered. The designed system is based on sensors that evaluate lightning discharge parameters by receiving electromagnetic radiation generated when an electric charge moves along the lightning channel. It is shown that mathematical modeling can be used to ensure the basic characteristics of the designed systems for monitoring lightning activity, such as the probability of detection, the accuracy of determining the coordinates and current of a lightning discharge for a selected working area. A model is proposed that makes it possible to design a system configuration capable of providing specified characteristics by obtaining model estimates and their subsequent analysis. The created model of a lightning activity monitoring system is used to estimate the probability of detecting a lightning discharge by an experimental network deployed in St. Petersburg.

Keywords: thunderstorm activity, lightning discharge, monitoring system, sensor sensitivity, electric field strength, distance to lightning discharge, detection probability

For citation: Postrybaylo M. V., Tatarnikova T. M. Model estimates of parameters of passive radio systems for monitoring lightning activity. *Journal of Instrument Engineering*. 2024. Vol. 67, N 4. P. 368—374 (in Russian). DOI: 10.17586/0021-3454-2024-67-4-368-374.

Введение. Гроза представляет собой распространенное природное явление, способное подвергнуть опасности жизни людей, нанести ущерб объектам инфраструктуры, стать причиной возникновения пожаров [1, 2]. Особую опасность грозы представляют для электроники и энергетических систем. От 40 до 70 % аварийных отключений воздушных линий электропередач связано с грозовой активностью [3]. Удары молнии могут повлиять на движение лета-

тельных аппаратов или нарушить их функционирование [4]. Также грозы могут сопровождать другие природные явления, такие как шторм, сильный ливневый дождь, град и др. [5, 6].

Оперативная и достоверная информация о грозовой активности, получаемая с помощью систем мониторинга грозовой активности, позволяет формировать прогнозы погоды, исследовать климат, проектировать системы грозозащиты различных объектов [1, 7, 8].

В настоящее время пассивные системы мониторинга грозовой активности могут состоять либо из автономных датчиков, способных получать оценку параметров молниевых разрядов (МР) из одной точки, или из датчиков, работающих в составе сетей, использующих триангуляционный либо разностно-дальномерный методы. Существуют также спутниковые системы, способные оценивать координаты МР за счет приема излучения в ближнем инфракрасном диапазоне [9, 10]. Настоящая статья посвящена пассивным системам мониторинга грозовой активности, использующим угломерный и разностно-дальномерный методы определения координат МР.

Очевидно, что основными характеристиками систем, важными для конечного пользователя, являются вероятность обнаружения, точность определения координат и параметров тока МР для выбранной рабочей зоны. Для получения заданных характеристик нужно выбрать тип датчика, метод определения координат МР, порог чувствительности и число датчиков. При решении этой задачи можно воспользоваться математическим моделированием. Модель позволяет выбрать методы, подходящие для получения данных о разрядах датчиками молний, а также спроектировать конфигурацию системы, способную обеспечить заданные характеристики посредством получения модельных оценок и их последующего анализа [11, 12].

В настоящей работе представлены модель системы мониторинга грозовой активности, позволяющей оценить вероятность обнаружения МР, и результаты оценивания для реальной экспериментальной сети, развернутой в Санкт-Петербурге [13].

Оценка вероятности обнаружения МР. Из литературы [14] известно, что амплитуды обратных ударов МР подчинены логнормальному распределению. При наличии данных о распределении амплитуд сигналов $p_R(x)$, принятых датчиком на расстоянии R , и чувствительности датчика E вероятность обнаружения МР можно найти по формуле:

$$P = \int_E^{+\infty} p_R(x) dx. \quad (1)$$

В диссертации [15] приведены параметры вероятностного распределения амплитуд напряженности электрического поля $p(x)$ для расстояния 100 км. Для решения задачи оценивания вероятности обнаружения МР можно пересчитать это распределение на заданное расстояние R либо использовать известное распределение амплитуд сигналов для расстояния 100 км и рассчитать пороговое значение $E_{\text{пор}}$ по формуле [16]:

$$E_{\text{пор}}(E, R) = E \left(\frac{R}{100} \right)^{\frac{R-100}{1000}}. \quad (2)$$

Таким образом, вероятность обнаружения МР датчиком на расстоянии R с известной функцией плотности распределения вероятности (ФПРВ) амплитуд напряженности электрического поля составит:

$$P = \int_{E_{\text{пор}}(E, R)}^{+\infty} p(x) dx. \quad (3)$$

Для сети из N датчиков вероятность обнаружения МР рассчитывается по формуле:

$$P = \prod_{i=1}^N P_i, \quad (4)$$

где P_i — вероятность обнаружения молнии i -м датчиком.

Таким образом, на вход предлагаемой модели передаются ФПРВ приведенных оценок напряженности электрического поля, чувствительность датчиков и расстояние до молниевых разрядов. Результатом работы модели является оценка вероятности обнаружения МР для заданной сети.

В качестве исходных данных использованы параметры ФПРВ, оценки которых приведены в [15] для экспериментально полученных значений. На рис. 1 представлена ФПРВ бимодального логнормального распределения (вертикальный пунктир — нормированное значение порога напряженности поля $E_{\text{пор}}$, оранжевый пунктир — ФПРВ с параметрами $\sigma = 0,35$, $\mu = 1,6$, зеленый пунктир — ФПРВ с $\sigma = 0,15$, $\mu = 2,28$).




Рис. 1

В настоящей работе модель реализована с помощью среды технических расчетов MatLab. На первом этапе задаются входные параметры модели, координаты используемых в системе датчиков. Далее ограничивается зона потенциальных положений молниевых разрядов, для каждой точки внутри зоны рассчитывается расстояние от приемника, и на основе имеющихся данных оценивается вероятность обнаружения МР для конкретной точки.

Результаты моделирования. Моделирование проводилось для системы, состоящей из пяти универсальных датчиков молний, реализующих угломерный и разностно-дальномерный методы определения координат МР [13]. Используемые сетью приемники расположены в местах:

- 1) НОЦ ВКА им. А.Ф. Можайского (59.95631, 30.28847);
- 2) кафедра радиофизики СПбГУ, Петергоф, (59.88134, 29.82509);
- 3) Центр детско-юношеского технического творчества и информационных технологий, Пушкинский район Ленинградской области (59.715553, 30.412581);
- 4) деревня Вартемяги Всеволожского района Ленинградской области (60.1708, 30.31895);
- 5) поселок Воейково Всеволожского района Ленинградской области (59.95014, 30.70945).

Для угломерного метода определения координат минимально-избыточное число датчиков равно трем, что позволяет минимизировать ошибку местоопределения при наличии МР

на одной оси с базой системы. На рис. 2 представлены оценки вероятности обнаружения молниевых разряда угломерным методом для трех датчиков сети.




Рис. 2

Для разностно-дальномерного метода определения координат использование четырех датчиков является минимально-избыточным, что позволяет однозначно определить координаты МР [17]. На рис. 3 представлены оценки вероятности обнаружения молниевых разряда разностно-дальномерным методом определения координат для четырех датчиков сети.




Рис. 3

Сравнив рис. 2 и 3, можно увидеть снижение значений оценок вероятности обнаружения МР с увеличением числа используемых датчиков, что соответствует результатам расчетов по формуле (4), а также, согласно (2) — с увеличением расстояния от центра сети до МР.

В настоящей работе с помощью модели оценена вероятность обнаружения МР для каждой возможной конфигурации из трех и четырех датчиков, использующихся в экспериментальной сети [13]. На рис. 4 и 5 изображены оценки вероятности обнаружения среди возможных конфигураций датчиков для угломерного (три датчика) и разностно-дальномерного методов (четыре датчика) соответственно.




Рис. 4




Рис. 5

На рис. 2—5 разноцветными точками представлены места расположения датчиков, используемых при оценке эффективности обнаружения, на вспомогательной цветной полосе справа градиент от светло-желтого к темно-синему цвету соответствует значениям оценки вероятности обнаружения.

Анализ результатов моделирования позволяет сделать вывод, что при равной чувствительности датчиков можно добиться различных значений вероятности обнаружения в зависимости от числа датчиков. По сравнению с разностно-дальномерным методом, при использовании угломерного метода оценка вероятности обнаружения выше, а площадь зон с равной оценкой эффективности обнаружения больше.

Вне зависимости от используемого метода определения координат возможным решением задачи обеспечения большей вероятности обнаружения является повышение чувствительности датчиков и уменьшение расстояния между ними.

Закключение. Использование предлагаемой модели при мониторинге грозовой активности позволит оценить вероятность обнаружения молниевых разрядов. Также модель может быть использована для определения конфигурации системы мониторинга с учетом положения датчиков и их чувствительности, а также метода определения координат молниевых разрядов.

Совместный учет зон равной точности и вероятности обнаружения МР с использованием предложенной модели позволит на качественно новом уровне анализировать возможности как существующих, так и перспективных систем мониторинга грозовой активности.

СПИСОК ЛИТЕРАТУРЫ

1. Пономарёв Е. И. Оценка рисков возникновения лесных пожаров в результате гроз на основе гис-ориентированной технологии // География и природные ресурсы. 2011. № 1. С. 150—154.
2. Бабилова Н. Н., Котелина Н. О., Тентюков Ф. Н. Анализ данных о лесных пожарах в республике Коми с помощью excel и python // Вестн. Сыктывкарского университета. Сер. 1. Математика. Механика. Информатика. 2023. № 4(49). С. 29—46.
3. Гайворонский А. Актуальные проблемы молниезащиты ВЛ110-500 кВ // Новости электротехники. 2019. № 1(115). С. 18—23.
4. Сагитов Д. И., Драгова Т. А., Булдакова И. А., Алимов А. В. Противодействие грозовым разрядам на фюзеляже воздушных судов // Актуальные проблемы науки и образования в условиях современных вызовов. Сборник материалов XXV Международной научно-практической конференции. М., 2023. С. 191—193.
5. Малкин Е. И., Чернева В. И., Махлай Д. О., Чернева Н. В., Акбашев Р. Р., Санников Д. В. Дистанционные методы наблюдений за извержениями вулканов Шивелуч и Безымянный // Вестник КРАУНЦ. Физико-математические науки. 2023. Т. 43, № 2. С. 141—165.
6. Хегай В. В., Карелин А. В. О связи интенсивности тропических ураганов с грозовой активностью. Взгляд из космоса // Вопросы электромеханики. Тр. ВНИИЭМ. 2021. Т. 180, № 1. С. 26—32.
7. Аджиева А. А., Шаповалов В. А. Совершенствование прогнозирования и контроля развития опасных явлений погоды с использованием радиолокационных и грозопеленгационных методов на примере отдельного грозового очага // Изв. вузов. Северо-Кавказский регион. Сер. Естественные науки. 2017. № 1(193). С. 80—88.
8. Аджиева А. А., Кокоева М. Н. Динамический мониторинг данных параметров токов молний на территории юга европейской части России // Инженерный вестник Дона. 2019. № 5(56). С. 3.
9. Денисенков Д. А., Коровин Е. А. Универсальный датчик системы мониторинга грозовой активности // Труды Военно-космической академии им. А.Ф. Можайского. 2016. № 653. С. 164—168.
10. Миклуш В. А., Татарникова Т. М., Палкин И. И. Решение задачи экологического мониторинга акватории порта с помощью распределенной системы датчиков // Изв. вузов. Приборостроение. 2021. Т. 64, № 5. С. 404—411.
11. Татарникова Т. М., Богданов П. Ю., Миклуш В. А. Алгоритм размещения датчиков системы экологического мониторинга // Телекоммуникации. 2022. № 3. С. 2—9.
12. Миклуш В. А., Татарникова Т. М. Решение задачи расположения датчиков различной физической природы при организации беспроводной сенсорной сети с топологией mesh // Успехи современной радиоэлектроники. 2022. Т. 76, № 12. С. 15—20.
13. Готюр И. А., Коровин Е. А., Чернышев С. В., Шукин Г. Г., Юсупов И. Е. Экспериментальная сеть датчиков мониторинга грозовой активности // Труды Военно-космической академии им. А.Ф. Можайского. 2022. № S685. С. 66—74.
14. Rakov V. A., Uman M. A. Lightning Physics and Effects. Cambridge University Press, 2014.
15. Юсупов И. Е. Исследование импульсного электромагнитного излучения грозового процесса в приложении к мониторингу грозовой активности: Дис. ... канд. физ. мат. наук. СПб, 2018. 202 с.
16. Снегуров А. В., Снегуров В. С. К экспериментальной оценке токов молний // Труды Главной геофизической обсерватории им. А.И. Воейкова. 2021. № 603. С. 79—129.
17. Поздняков Е. К., Ткаченко В. Н., Коротков В. В. Увеличение точности определения координат пассивными трехпозиционными комплексами в условиях избыточности // Радиотехника и информатика. 2013. № 3(62). С. 3—6.

Сведения об авторах

- | | |
|---------------------------------------|---|
| Макар Витальевич Пострыбайло | — аспирант; Санкт-Петербургский государственный университет аэрокосмического приборостроения, кафедра прикладной информатики; E-mail: m.postrybaylo@yandex.ru |
| Татьяна Михайловна Татарникова | — д-р техн. наук, профессор; Санкт-Петербургский государственный университет аэрокосмического приборостроения, кафедра прикладной информатики; профессор; E-mail: tm-tatarn@yandex.ru |

Поступила в редакцию 04.12.23; одобрена после рецензирования 07.12.23; принята к публикации 08.02.24.

REFERENCES

1. Ponomarev E.I. *Geografiya i prirodnyye resursy* (Geography and Natural Resources), 2011, no. 1, pp. 150–154. (in Russ.)
2. Babikova N.N., Kotelina N.O., Tentyukov F.N. *Vestnik Syktyvkar'skogo universiteta. Seriya 1: Matematika. Mekhanika. Informatika* (Bulletin of Syktyvkar University. Series 1: Mathematics. Mechanics. Computer science), 2023, no. 4(49), pp. 29–46. (in Russ.)
3. Gayvoronskiy A. *Novosti elektrotekhniki*, 2019, no. 1(115), pp. 18–23. (in Russ.)
4. Sagitov D.I., Dragova T.A., Buldakova I.A., Alimov A.V. *Aktual'nyye problemy nauki i obrazovaniya v usloviyakh sovremennykh vyzovov* (Current Problems of Science and Education in the Context of Modern Challenges), Collection of materials of the XXV International Scientific and Practical Conference, Moscow, 2023, pp. 191–193. (in Russ.)
5. Malkin E.I., Cherneva V.I., Makhlai D.O., Cherneva N.V., Akbashev R.R., Sannikov D.V. *Vestnik KRAUNTS. Fiziko-matematicheskiye nauki* (Vestnik KRAUNTS. Physical and Mathematical Sciences), 2023, no. 2(43), pp. 141–165. (in Russ.)
6. Khagai V.V., Karelin A.V. *Electromechanical matters. VNIIE studies*, 2021, no. 1(180), pp. 26–32. (in Russ.)
7. Adjieva A.A., Shapovalov V.A. *Bulletin of Higher Educational Institutions. North Caucasus Region. Natural Sciences*, 2017, no. 1(193), pp. 80–88. (in Russ.)
8. Adzhieva A.A., Kokoeva M.N. *Engineering Journal of Don*, 2019, no. 5(56), pp. 3. (in Russ.)
9. Denisenkov D.A., Korovin E.A. *Proceedings of the A.F. Mozhaisky Military Space Academy*, 2016, no. 653, pp. 164–168. (in Russ.)
10. Miklush V.A., Tatarnikova T.M., Palkin I.I. *Journal of Instrument Engineering*, 2021, no. 5(64), pp. 404–411. (in Russ.)
11. Tatarnikova T.M., Bogdanov P.Yu., Miklush V.A. *Telecommunications*, 2022, no. 3, pp. 2–9. (in Russ.)
12. Miklush V.A., Tatarnikova T.M. *Uspekhi sovremennoy radioelektroniki*, 2022, no. 12(76), pp. 15–20. (in Russ.)
13. Gotyur I.A., Korovin E.A., Chernyshev S.V., Shchukin G.G., Yusupov I.E. *Proceedings of the A.F. Mozhaisky Military Space Academy*, 2022, no. S685, pp. 66–74. (in Russ.)
14. Rakov V.A., Uman M.A. *Lightning Physics and Effects*, Cambridge University Press, 2014.
15. Yusupov I.E. *Issledovaniye impul'snogo elektromagnitnogo izlucheniya grozovogo protsessa v prilozhenii k monitoringu grozovoy aktivnosti* (Study of Pulsed Electromagnetic Radiation of a Thunderstorm Process as Applied to Monitoring of Lightning Activity), Candidate's thesis, St. Petersburg, 2018, 202 p. (in Russ.)
16. Snegurov A.V., Snegurov V.S. *Proceedings of Voeikov Main Geophysical Observatory*, 2021, no. 603, pp. 79–129. (in Russ.)
17. Pozdnyakov E.K., Tkachenko V.N., Korotkov V.V. *Radiotekhnika i informatika*, 2013, no. 3(62), pp. 3–6. (in Russ.)

Data on authors

Makar V. Postrybaylo	—	Post-Graduate Student; St. Petersburg State University of Aerospace Instrumentation, Department of Applied Informatics; E-mail: m.postrybaylo@yandex.ru
Tatyana M. Tatarnikova	—	Dr. Sci., Professor, St. Petersburg State University of Aerospace Instrumentation, Department of Applied Informatics; Professor; E-mail: tm-tatarn@yandex.ru

Received 04.12.23; approved after reviewing 07.12.23; accepted for publication 08.02.24.

КРАТКИЕ СООБЩЕНИЯ

BRIEF NOTES

УДК 004.4:004.94:528.8
DOI: 10.17586/0021-3454-2024-67-4-375-379

ИНФОРМАЦИОННО-АНАЛИТИЧЕСКИЙ СЕРВИС: ПОДХОД К АНАЛИЗУ ГЕОПРОСТРАНСТВЕННЫХ ДАННЫХ СПУТНИКОВОГО МОНИТОРИНГА

Е. Ф. Чичкова*, Д. А. Кочин, С. А. Рогачев

Санкт-Петербургский государственный университет аэрокосмического приборостроения

Санкт-Петербург, Россия

**efchichkova@yandex.ru*

Аннотация. Представлен подход к анализу и управлению данными при проведении спутникового экологического мониторинга территорий и интерпретации полученных результатов. Подход основан на опыте прикладных исследований при проведении ежегодного спутникового мониторинга заданных территорий в Северо-Западном регионе РФ. Цифровые карты геопространственных слоев информации, построенные на основе космической информации различного пространственного разрешения и материалов полевых обследований заданных территорий, рассматриваются как геоданные для мониторинга параметров контролируемых из космоса объектов и определения экологически потенциально опасных зон. Разработан геопортал — программно-технический комплекс обработки данных и представления результатов распознавания характеристик земель. Результаты экологического мониторинга состояния природных и техногенных объектов являются выходными геоданными геопортала для пользователей, а также — сохраненные в архиве — источником данных для проведения дальнейшего мониторинга межвременной и пространственной изменчивости компонентов среды. В настоящее время результаты исследований наиболее востребованы при проведении производственно-экологического мониторинга в нефтегазовой, строительной и сельскохозяйственной отраслях.

Ключевые слова: геопортал, геопространственные данные, экологический мониторинг, обработка информации, космический аппарат

Благодарности: работа выполнена при финансовой поддержке по теме Госзадания № FSRF-2023-0003.

Ссылка для цитирования: Чичкова Е. Ф., Кочин Д. А., Рогачев С. А. Информационно-аналитический сервис: подход к анализу геопространственных данных спутникового мониторинга // Изв. вузов. Приборостроение. 2024. Т. 67, № 4. С. 375—379. DOI: 10.17586/0021-3454-2024-67-4-375-379.

INFORMATION AND ANALYTICAL SERVICE: APPROACH TO ANALYZING GEOSPATIAL DATA FROM SATELLITE-BASED MONITORING

E. F. Chichkova*, D. A. Kochin, S. A. Rogachev

St. Petersburg State University of Aerospace Instrumentation, St. Petersburg, Russia

**efchichkova@yandex.ru*

Abstract. An approach to analyzing and managing data when conducting satellite environmental monitoring of territories and interpreting the results obtained is presented. The approach is based on the experience of applied research during annual satellite monitoring of specified territories in the North-West region of the Russian Federation. Digital maps of geospatial layers of information, built on the basis of space information of various spatial resolutions and materials from field surveys of given territories, are considered as geodata for monitoring the parameters of objects controlled from space and identifying environmentally potentially hazardous areas. A geoportal - a software and hardware complex for processing data and presenting the results of recognition of land characteristics - is developed. The results of environmental monitoring of the state of objects are the output geodata of the geoportal for users, and also, stored in the archive, a source of data for further monitoring of intertemporal and spatial variability of environmental components.

Currently, the results of the studies are most in demand when conducting industrial and environmental monitoring in the oil and gas industries, construction and agriculture.

Keywords: geoportal, geospatial data, environmental monitoring, data processing, spacecraft

Acknowledgment: The work was carried out with financial support on the topic of State Assignment No. FSRF-2023-0003.

For citation: Chichkova E. F., Kochin D. A., Rogachev S. A. Information and analytical service: approach to analyzing geospatial data from satellite-based monitoring. *Journal of Instrument Engineering*. 2024. Vol. 67, N 4. P. 375—379 (in Russian). DOI: 10.17586/0021-3454-2024-67-4-375-379.

Спутниковый мониторинг является составной частью экологического мониторинга территорий, выполнение которого регламентируется требованиями природоохранного законодательства* и различными нормативными документами в области охраны окружающей среды. Информационно-аналитический сервис центра космических услуг „КосмоИнформ-Центр“ ГУАП предназначен для обработки данных, получаемых при помощи многоспектрального зондирования с различных космических аппаратов (КА), и материалов маршрутных обследований для решения прикладных задач отраслей первичного сектора экономики [1, 2]. Функционально сервис может быть отнесен к информационно-аналитическим системам, обеспечивающим экологический мониторинг регионального масштаба [3—5]. Методы формирования и использования геоданных в различных научных и исследовательских сферах представлены в работе [6].

Основой информационно-аналитического сервиса для получения, обработки, анализа и визуализации геоданных является геоportal, разработанный Центром космических услуг ГУАП. Геоportal представляет собой программно-технический комплекс (рис. 1). В его состав входит ряд сервисов.

Сервисы получения (скачивания) данных представляют собой программные модули, позволяющие в автоматическом режиме получать геоданные из открытых источников, таких как Copernicus Contributing Missions, в частности — данные спутниковой группировки Sentinel. Сервисы предварительной обработки данных дистанционного зондирования Земли предназначены для приведения геоданных к унифицированному формату. Файловый каталог содержит исходные данные, представленные как в запакованном виде (в виде архивов), так и в растровых и векторных форматах. Этот компонент геоportала выполняет также роль источника данных для проведения мониторинга межвременной изменчивости компонентов среды.



Рис. 1

* Федеральный закон „Об охране окружающей среды“ от 10.01.2002 N 7-ФЗ (в ред. от 25 декабря 2023).

В программных средствах тематической обработки и анализа геоданных используются предлагаемые международным консорциумом Open Geospatial Consortium (OGC) технологии, в частности геоинформационная открытая система Quantum GIS (QGIS). Преимуществом системы QGIS является широкий выбор встроенных средств обработки, анализа, представления и публикации данных. Наличие системы подключения и распространения модулей (плагинов) позволяет настраивать самостоятельно разработанные программные модули под требования выполняемых задач. Функционал системы хорошо документирован. Для расширенной тематической обработки геоданных также используется проприетарная ГИС ERDAS Imagine.

Доступ потребителей к геоданным организован при помощи программного обеспечения GEOSERVER и системы управления пространственными базами данных PostGIS, которые содержат средства для хранения растровых и векторных материалов, а также метаданные оформления и визуализации. Передача данных осуществляется с помощью сервисов OSG, в частности Web Map Service (WMS), Web Feature Service (WFS) и Web Coverage Service (WCS).

Для предоставления потребителям доступа к геоданным используется веб-интерфейс, специально разработанный для геопортала. Основой его является веб-приложение, использующее библиотеку OpenLayers. Такое решение позволяет создавать динамические карты, управлять геоданными и отображать их, загруженные из любого источника, а также осуществлять разграничение прав доступа к данным.

Исходными данными представленного сервиса для проведения экологического мониторинга служат геопространственные данные спутниковой многоспектральной съемки высокого (KA WorldView-2,3; GeoEye-1 и др.) и среднего (группировки KA Sentinel-2 и Landsat) пространственного разрешения, картографические материалы, данные маршрутных обследований территорий.

Обработанные геоданные содержат дешифрованные или рассчитанные по спектральным характеристикам параметры, характеризующие состояние компонентов среды или их изменение. При проведении спутникового экологического мониторинга параметры контроля состояния заданных территорий (например, наличие эрозионных процессов, процессов заболачивания и подтопления, состояние растительного покрова) определяются исходя из задач, поставленных заказчиком.

Геопортал представляет собой набор специализированных карт и слоев информации в векторном и растровом виде, а также атрибутивную информацию о рассчитанных линейных, площадных и статистических характеристиках заданных параметров. На рис. 2 представлены результаты выполненных в 2022—2023 гг. геопортальных проектов по оценке динамики ареалов борщевика Сосновского (БС) [7] для участка земель сельскохозяйственного назначения Волосовского района Ленинградской области. Геопортальные проекты по БС разработаны по заказу Комитета по агропромышленному и рыбохозяйственному комплексу Ленинградской области.



Рис. 2

В целом использование геопортала позволяет оптимизировать процесс извлечения полезной информации о параметрах компонентов окружающей среды и их изменений и организовывать удобный доступ к геоданным. Перспективным направлением развития представленного информационно-аналитического сервиса в настоящий момент является создание специализированного приложения, в частности для мобильной платформы, с целью обеспечения работ с геоданными при полевых обследованиях территорий заказчиков.

СПИСОК ЛИТЕРАТУРЫ

1. Чичкова Е. Ф., Кочин Д. А., Рогачев С. А. Информационно-аналитический сервис и технологии мониторинга потенциально опасных зон по данным спутникового многоспектрального зондирования // Космические аппараты и технологии. 2023. Т. 7, № 2. С. 132—141. DOI: 10.26732/j.st.2023.2.06.
2. Свид-во о гос. рег. программы для ЭВМ № 2021681898 РФ. Геоинформационный ресурс для представления разнородной пространственной информации "CSS-WebMap" / Д. А. Кочин, С. А. Рогачев. Заяв. № 2021681673 от 27.12.2021, опубл. 27.12.2021.
3. Рогачев С. А., Матвеев В. А. Веб-картография. Представление разнородной пространственной информации // Тр. СПИИРАН. 2013. № 6(29). С. 132—143.
4. Соколов С. С., Сторчак Т. В., Тихомиров Я. Н. Разработка информационно-аналитической системы экологического мониторинга для слежения за текущим состоянием окружающей среды на территории нефтяных месторождений // Бюллетень науки и практики. 2017. № 4. С. 170—183.
5. Путивцева Н. П., Наливко К. В. Автоматизированная система экологического мониторинга // Проблемы современной науки и образования. 2013. № 4(18). С. 22—23.
6. Apollo M., Jakubiak M., Nistor S. et al. Geodata in science - a review of selected scientific fields // Acta Scientiarum Polonorum. Formatio Circumiectus. 2023. Vol. 22, N 2. P. 17—40. DOI:10.15576/ASP.FC/2023.22.2.02.
7. Пат. РФ 2657363 С1, МПК G01V 9/00, G01N 21/25. Способ определения параметров состояния почвенно-растительного покрова по данным многоспектрального аэрокосмического зондирования / А. Н. Григорьев, В. В. Зайцев, Д. М. Рыжиков, Е. Ф. Чичкова. Заяв. № 2017113843 от 20.04.2017, опубл. 13.06.2018.

Сведения об авторах

- Елена Федоровна Чичкова** — канд. геогр. наук; Санкт-Петербургский государственный университет аэрокосмического приборостроения, КосмоИнформ-центр ГУАП; директор ЦКУ; E-mail: efchichkova@yandex.ru
- Дмитрий Александрович Кочин** — Санкт-Петербургский государственный университет аэрокосмического приборостроения, КосмоИнформ-центр ГУАП; науч. сотр. ЦКУ; E-mail: dimakohin@yandex.ru
- Сергей Александрович Рогачев** — Санкт-Петербургский государственный университет аэрокосмического приборостроения, кафедра компьютерных технологий и программной инженерии; старший преподаватель; E-mail: rogachev.seal@gmail.com

Поступила в редакцию 04.12.23; одобрена после рецензирования 12.12.23; принята к публикации 08.02.24.

REFERENCES

1. Chichkova E.F., Kochin D.A., Rogachev S.A. *Spacecrafts & Technologies*, 2023, no. 2(7), pp. 132–141, DOI: 10.26732/j.st.2023.2.06. (in Russ.)
2. Certificate on the state registration of the computer programs 2021681898, *Geoinformatsionnyy resurs dlya predstavleniya raznorodnoy prostranstvennoy informatsii "CSS-WebMap"* (Geoinformation Resource for Representing Heterogeneous Spatial Information "CSS-WebMap"), D.A. Kochin, S.A. Rogachev, Application no. 2021681673, Priority 27.12.2021, Published 27.12.2021. (in Russ.)
3. Rogachev S.A. *Informatics and Automation* (SPIIRAS Proceedings), 2013, no. 6(29), pp. 132–143. (in Russ.)
4. Sokolov S., Storchak T., & Tikhomirov Ya. *Bulletin of Science and Practice*, 2017, no. 4, pp. 170–183. (in Russ.)
5. Putivtseva N.P., Nalivko K.V. *Problemy sovremennoi nauki i obrazovaniya*, 2013, no. 4, pp. 22–23. (in Russ.)
6. Apollo M., Jakubiak M., Nistor S. et al. *Acta Scientiarum Polonorum. Formatio Circumiectus*, 2023, no. 2(22), pp. 17–40, DOI:10.15576/ASP.FC/2023.22.2.02.

7. Patent RU 2657363 C1, G01V 9/00, G01N 21/25, *Sposob opredeleniya parametrov sostoyaniya pochvenno-rastitel'nogo pokrova po dannym mnogospektral'nogo aerokosmicheskogo zondirovaniya* (A method for Determining the Parameters of the State of Soil and Vegetation Cover According to Multispectral Aerospace Sounding Data), A.N. Grigoriev, V.V. Zaitsev, D.M. Ryzhikov, E.F. Chichkova, Patent application no. 2017113843, Priority 20.04.2017, Published 13.06.2018. (in Russ.)

Data on authors

- Elena F. Chichkova** — PhD; St. Petersburg State University of Aerospace Instrumentation, Center of space services "Kosmo-Inform-Center"; Director of the Center;
E-mail: efchichkova@yandex.ru
- Dmitriy A. Kochin** — St. Petersburg State University of Aerospace Instrumentation, Center of space services "Kosmo-Inform-Center"; Researcher; E-mail: dimakohin@yandex.ru
- Sergei A. Rogachev** — PhD; St. Petersburg State University of Aerospace Instrumentation, Department of Computer Technologies and Software Engineering; Senior Lecturer;
E-mail: rogachev.seal@gmail.com

Received 04.12.23; approved after reviewing 12.12.23; accepted for publication 08.02.24.