

ISSN 2500—0381

Электронная версия

ISSN 0021—3454


Печатная версия

ИЗВЕСТИЯ ВЫСШИХ УЧЕБНЫХ ЗАВЕДЕНИЙ

# ПРИБОРОСТРОЕНИЕ


НАУЧНО-ТЕХНИЧЕСКИЙ

ЖУРНАЛ



№ 11

т. 66  
2023



Journal of Instrument Engineering

## 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. БОГАТЬЕВ, 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 „Электроприбор“», 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 И. М. Игошина*

*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/*

---

*Подписано в печать 30.11.2023 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 отнести  
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/>  
E-mail: [pribor@itmo.ru](mailto: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](mailto: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: каждый на отдельном листе формата А4 (не заверстывать в текст), таблицы.

Объем текста (оформленного в соответствии с требованиями журнала — шрифт Times New Roman, размер — 14 пт, межстрочный 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 только 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.

МИНИСТЕРСТВО НАУКИ И ВЫСШЕГО ОБРАЗОВАНИЯ РОССИЙСКОЙ ФЕДЕРАЦИИ  
ИЗВЕСТИЯ ВЫСШИХ УЧЕБНЫХ ЗАВЕДЕНИЙ

# ПРИБОРОСТРОЕНИЕ

ИЗДАНИЕ УНИВЕРСИТЕТА ИТМО  
Журнал издается с января 1958 г.

ТОМ 66

НОЯБРЬ 2023

№ 11

## СОДЕРЖАНИЕ

### ИНФОРМАТИКА И ИНФОРМАЦИОННЫЕ ПРОЦЕССЫ

Аверьянов А. В., Нгуен В. Т. Проверка согласия теоретического и эмпирического распределений Парето для команд и микрокоманд ЭВМ с помощью критерия Колмогорова.....	899
Мартынчук И. Г. Прогнозирование мульти сезонных нагрузочных процессов в эластичных вычислительных системах .....	907

### СИСТЕМНЫЙ АНАЛИЗ, УПРАВЛЕНИЕ И ОБРАБОТКА ИНФОРМАЦИИ

Столбов А. В., Спесивцев А. В., Лисицкий В. В., Спесивцев В. А. Методика оценивания системы эксплуатации сложных объектов на основе нечетко-возможностного подхода.....	917
Shakkouf A. Review on Optimization Techniques of Binary Neural Networks.....	926

### КОМПЬЮТЕРНОЕ МОДЕЛИРОВАНИЕ

#### И АВТОМАТИЗАЦИЯ ПРОЕКТИРОВАНИЯ

Соколов В. Г., Потемин И. С., Жданов Д. Д. Методика эффективного компьютерного моделирования устройства измерения светорассеивающих свойств.....	936
--	-----

### ВЫЧИСЛИТЕЛЬНЫЕ СИСТЕМЫ И ИХ ЭЛЕМЕНТЫ

Титов В. С., Шевелев С. С. Арифметический вычислитель на элементах нейронной логики .....	950
---	-----

### ОПТИЧЕСКИЕ И ОПТИКО-ЭЛЕКТРОННЫЕ ПРИБОРЫ И КОМПЛЕКСЫ

Гулаков И. Р., Зеневич А. О., Кочергина О. В. Эффективная фоточувствительная поверхность кремниевых фотоумножителей .....	960
---	-----

### ПРИБОРЫ, СИСТЕМЫ И ИЗДЕЛИЯ МЕДИЦИНСКОГО НАЗНАЧЕНИЯ

Коденко М. Р., Самородов А. В., Кульберг Н. С., Решетников Р. В. Создание наборов данных компьютерной томографии брюшной аорты с подавлением контрастирования для обучения и тестирования алгоритмов искусственного интеллекта.....	968
---	-----

### ПРИБОРЫ И МЕТОДЫ КОНТРОЛЯ И ДИАГНОСТИКИ

#### МАТЕРИАЛОВ, ИЗДЕЛИЙ, ВЕЩЕСТВ И ПРИРОДНОЙ СРЕДЫ

Полонский В. Л., Тарабенко Е. А., Иванова Г. В. Оценка прочности эластомерных мембранных контроллеров давления .....	982
--	-----

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 *Irina M. Igoshina*

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

E-mail: [pribor@itmo.ru](mailto:pribor@itmo.ru)

THE MINISTRY OF SCIENCE AND HIGHER EDUCATION OF THE RUSSIAN FEDERATION

# JOURNAL OF INSTRUMENT ENGINEERING

ITMO UNIVERSITY

The Journal is published since January 1958

Vol. 66

NOVEMBER 2023

No 11

## CONTENTS

### INFORMATICS AND INFORMATION PROCESSES

- Averyanov A. V., Nguyen V. T. Checking the Agreement of Theoretical and Empirical Pareto Distributions for Computer Commands and Microcommands Using the Kolmogorov Criterion ..... 899  
Martynchuk I. G. Forecasting Multi-Seasonal Load Processes in Elastic Computing Systems ..... 907

### SYSTEM ANALYSIS, CONTROL, AND INFORMATION PROCESSING

- Stolbov A. V., Spesivtsev A. V., Lisitskiy V. V., Spesivtsev V. A. Methodology for Assessing the Operation System of Complex Objects Based on the Fuzzy-Possibility Approach ..... 917  
Shakkouf A. Review on Optimization Techniques of Binary Neural Networks ..... 926

### COMPUTER SIMULATION AND DESIGN AUTOMATION

- Sokolov V. G., Potemin I. S., Zhdanov D. D. Methodology for Effective Computer Modeling of a Device for Measuring Light Scattering Properties ..... 936

### COMPUTING SYSTEMS AND THEIR ELEMENTS

- Titov V. S., Shevelev S. S. Arithmetic Calculator Based on Neural Logic Elements ..... 950

### OPTICAL AND OPTO-ELECTRONIC INSTRUMENTS AND COMPLEXES

- Gulakov I. R., Zenevich A. O., Kochergina O. V. Effective Photosensitive Surface of Silicon Photomultipliers ..... 960

### MEDICAL DEVICES, SYSTEMS, AND PRODUCTS

- Kodenko M. R., Samorodov A. V., Kulberg N. S., Reshetnikov R. V. Creating Contrast-Suppressed Abdominal Aorta CT Datasets for Training and Testing Artificial Intelligence Algorithms ..... 968

### INSTRUMENTS AND METHODS FOR MONITORING AND DIAGNOSING MATERIALS, PRODUCTS, SUBSTANCES AND THE NATURAL ENVIRONMENT

- Polonsky V. L., Tarasenko E. A., Ivanova G. V. Evaluation of the Strength of Elastomeric Membranes of Pressure Control Devices ..... 982

## 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](mailto: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*

---

# ИНФОРМАТИКА И ИНФОРМАЦИОННЫЕ ПРОЦЕССЫ

## INFORMATICS AND INFORMATION PROCESSES

---

УДК 621.396.6

DOI: 10.17586/0021-3454-2023-66-11-899-906

### ПРОВЕРКА СОГЛАСИЯ ТЕОРЕТИЧЕСКОГО И ЭМПИРИЧЕСКОГО РАСПРЕДЕЛЕНИЙ ПАРЕТО ДЛЯ КОМАНД И МИКРОКОМАНД ЭВМ С ПОМОЩЬЮ КРИТЕРИЯ КОЛМОГОРОВА

А. В. АВЕРЬЯНОВ\*, В. Т. НГҮЕН

Военно-космическая академия им. А. Ф. Можайского, Санкт-Петербург, Россия  
\*vka\_24kaf@mail.ru

**Аннотация.** Выполнена проверка гипотезы о согласии теоретического и эмпирического распределений Парето применительно к кумулятивным кривым — диаграммам для команд и микрокоманд учебной ЭВМ. В качестве статистического критерия согласия использован критерий Колмогорова. Получены значения параметров для функций распределения Парето, описывающих вероятностные свойства случайных величин, которыми являются порядковые номера команд и реализующих их микрокоманд. Построены графики теоретических и практических функций распределения, позволяющие исключить из системы команд ЭВМ редко используемые команды, что способствует упрощению архитектуры процессоров ЭВМ. Отдельные теоретические положения и полученные практические результаты являются дальнейшим развитием статистического метода повышения качества — анализа Парето применительно к количественному оцениванию метрик машинных команд и микрокоманд ЭВМ.

**Ключевые слова:** критерий Колмогорова, функция распределения Парето, кумулятивная кривая Парето, уровень значимости, квантиль распределения, доверительный интервал, команды и микрокоманды ЭВМ, устройство управления ЭВМ

**Ссылка для цитирования:** Аверьянов А. В., Нгүен В. Т. Проверка согласия теоретического и эмпирического распределений Парето для команд и микрокоманд ЭВМ с помощью критерия Колмогорова // Изв. вузов. Приборостроение. 2023. Т. 66, № 11. С. 899—906. DOI: 10.17586/0021-3454-2023-66-11-899-906.

### CHECKING THE AGREEMENT OF THEORETICAL AND EMPIRICAL PARETO DISTRIBUTIONS FOR COMPUTER COMMANDS AND MICROCOMMANDS USING THE KOLMOGOROV CRITERION

A. V. Averyanov\*, V. T. Nguyen

A. F. Mozhaisky Military Space Academy, St. Petersburg, Russia  
vka\_24kaf@mail.ru

**Abstract.** The hypothesis about the agreement of theoretical and empirical Pareto distributions is tested in relation to cumulative curves - diagrams for instructions and microinstructions of an educational computer. The Kolmogorov criterion is used as a statistical criterion for agreement. The values of the parameters are obtained for the Pareto distribution functions that describe the probabilistic properties of random variables, which are the ordinal numbers of commands and microcommands implementing them. Constructed graphs of theoretical and practical distribution functions make it possible to exclude rarely used commands from the computer command system, which helps to simplify the architecture of computer processors. Certain theoretical principles and the obtained practical results are a further development of the statistical method of improving quality, i.e. Pareto analysis, in relation to quantitative assessment of metrics of machine commands and microcommands of a computer.

**Keywords:** Kolmogorov criterion, Pareto distribution function, cumulative Pareto curve, significance level, distribution quantile, confidence interval, computer commands and microcommands, computer control device

**For citation:** Averyanov A. V., Nguyen V. T. Checking the agreement of theoretical and empirical Pareto distributions for computer commands and microcommands using the Kolmogorov criterion. *Journal of Instrument Engineering*. 2023. Vol. 66, N 11. P. 899—906 (in Russian). DOI: 10.17586/0021-3454-2023-66-11-899-906.

При решении ряда статистических задач вводится предположение, что некоторые случайные величины имеют заданное распределение (нормальное, экспоненциальное, равномерное и др.) с известными или неизвестными параметрами. При этом необходимо ответить на вопрос: насколько сделанные предположения о распределении случайных величин соответствуют опытным данным? Для решения этой задачи разработаны разные способы, иначе говоря, статистические критерии. Критериями согласия называют статистические критерии, предназначенные для обнаружения расхождений между гипотетической статистической моделью и реальными данными, которые эта модель призвана описать [1]. Важнейшим из этих критериев является критерий Колмогорова.

При использовании критерия Колмогорова в качестве меры расхождения теоретического и эмпирического распределений принимают число  $D_N$  [2], которое вычисляется по формуле

$$D_N = \sqrt{N} \cdot D_{\max}, \quad (1)$$

где  $N$  — количество испытаний,  $D_{\max}$  — максимальная абсолютная разность теоретической и эмпирической функций распределения случайной величины  $x$ , т.е.

$$D_{\max} = \max_j |F(x_j) - \hat{F}(x_j)|. \quad (2)$$

В связи с тем, что значения эмпирической функции  $\hat{F}(x_j)$  являются случайными, мера расхождения  $D_N$  есть случайная величина.

Для проверки гипотезы о правильности выбора теоретической функции распределения  $F(x_j)$  задаются уровнем значимости  $\alpha$  и находят квантиль распределения Колмогорова  $z_{1-\alpha}$ . Уровень значимости  $\alpha$  определяет максимальное значение меры расхождения (1), которое можно считать случайным. Если в результате сравнения окажется, что  $D_N < z_{1-\alpha}$ , то делается заключение, что нет основания отвергнуть принятую гипотезу о виде функции распределения. В противном случае принятая на начальном этапе гипотеза отвергается и вся последовательность обработки информации повторяется, начиная с уточнения гипотезы о виде функции распределения. Квантили распределения Колмогорова приведены в табл. 1.

Таблица 1

$\alpha$	$z_{1-\alpha}$	$\alpha$	$z_{1-\alpha}$
0,01	1,63	0,20	1,07
0,025	1,48	0,25	1,02
0,05	1,36	0,30	0,97
0,10	1,22	0,35	0,93
0,15	1,14	0,40	0,89

Процедура проверки гипотезы по критерию Колмогорова состоит из следующих этапов.

1. Построение эмпирической функции распределения.
2. Выдвижение гипотезы о функции распределения и оценивание параметров этого распределения.

3. Вычисление значения теоретической функции распределения в точках  $x_j$ , которые соответствуют скачкам эмпирической функции распределения.

4. Вычисление в каждой из точек абсолютной разности

$$D_j = |F(x_j) - \hat{F}(x_j)|. \quad (3)$$

5. Выбор максимальной разности  $D_{\max}$  и определение величины  $D_N$ .

6. Сравнение меры расхождения  $D_N$  с квантилем  $z_{1-\alpha}$  распределения Колмогорова.

Применим рассмотренную процедуру для проверки гипотезы о правильности выбора функций распределений, соответствующих кумулятивным кривым-диаграммам Парето для команд и микрокоманд учебной ЭВМ. Критерий Колмогорова прост, но его применение на практике осложняется следующими обстоятельствами. Для сопоставления функций опытного и теоретического распределений необходимо знать параметры распределения, которые обычно определяются по результатам испытаний [2].

Кумулятивная кривая математически соответствует функции распределения Парето, которая задается равенством

$$F_X(x) = P(X < x) = 1 - \left( \frac{x_m}{x} \right)^k \quad \text{для } x \geq x_m; \quad x_m > 0; \quad k > 0, \quad (4)$$

где  $X$  — случайная величина;  $x$  — значение случайной величины  $X$ ;  $k$  и  $x_m$  — параметры распределения Парето.

Для проверки согласия теоретического и эмпирического распределений с помощью критерия Колмогорова были выполнены 50 программ в мнемокодах учебной ЭВМ [3, 4]. Все использованные команды, реализующие выполненные программы, указаны в таблице [5, табл. 1], на основе которой строится диаграмма Парето. Первая графа таблицы соответствует 37 командам, используемым в 50 программах. Система команд учебной ЭВМ состоит из 42 команд. Пять команд при программировании не использовались. В последней графе таблицы показана накопленная доля от суммарного числа повторений, выраженная в процентах, для каждой команды. Значения накопленных долей соответствуют значениям  $\hat{F}(x)$  — эмпирической функции распределения. В данном случае  $x$  — порядковый номер команды в указанной таблице [5, табл. 1], являющийся значением случайной величины  $X$  в формуле (4).

Команды, используемые при программировании, реализуются на микропрограммном уровне 48 микрокомандами, представленными в другой таблице [5, табл. 2], которая также была использована для построения кумулятивной кривой Парето.

Выдвигаем гипотезу о том, что поведение случайной величины  $X$ , соответствующей порядковым номерам команд и микрокоманд, описывается двухпараметрическим распределением Парето. Для сравнения эмпирической функции (кумулятивной кривой) и теоретической функции распределения необходимо определить значения параметров  $k$  и  $x_m$ .

Параметр  $x_m$  должен быть задан таким, чтобы любое значение случайной величины  $X$  было не меньше  $x_m$ , т.е.  $x \geq x_m$ . Как следует из собранного статистического материала, возможное минимальное значение случайной величины  $X$  соответствует первой команде или микрокоманде в рассмотренных таблицах [5, табл. 1, 2]. Поэтому задаем значение  $x_m = 1$ .

Параметр  $k$  является параметром масштаба, который имеет разные значения, зависящие от конкретного испытания. Задача нахождения параметра теоретической функции распределения при наличии совокупности опытных данных — точек — называется задачей „подгонка кривой“ [6, 7]. Решение подобной задачи заключается в вычислении наименьшей

суммы квадратов разностей между значениями теоретической и эмпирической функций распределений.

Для представленных в указанных таблицах [5] статистических данных на основе решения задачи „подгонка кривой“ получены следующие значения параметров масштаба: для мнемокоманд  $k = 0,66$  и реализующих их микрокоманд  $k = 0,70$ .

На рис. 1, а, б представлены графики эмпирической и теоретической функций распределения для команд с  $k = 0,66$  (а) и микрокоманд с  $k = 0,70$  (б) и заданным параметром  $x_m$ .




Рис. 1

Полученные графики позволяют осуществить проверку согласия теоретического и эмпирического распределений с помощью критерия Колмогорова. Для этого необходимо рассчитать по формуле (2) максимальную абсолютную разность  $D_{\max}$ .

В табл. 2 представлены результаты расчета разности  $D_j$  эмпирической  $\hat{F}(x_j)$  и теоретической  $F(x_j)$  функций распределений по формуле (3). Значение эмпирической функции — накопленные доли от суммарного числа повторений команд в 50 программах.

По табл. 2 легко определить максимальную разность  $D_{\max} = 0,17$ . Значение  $D_N$  рассчитывается по формуле (1) для количества испытаний  $N = 50$ , поскольку были рассмотрены 50 программ. Под испытанием понимается процесс реализации одной программы:

$$D_N = \sqrt{N} \cdot D_{\max} = \sqrt{50} \cdot 0,17 = 1,202.$$

Таблица 2

Случайная величина $x$	Значение функции $\hat{F}(x_j)$	Значение функции $F(x_j)$	Разность $D_j$	Случайная величина $x$	Значение функции $\hat{F}(x_j)$	Значение функции $F(x_j)$	Разность $D_j$
1	0	0	0	20	0,93	0,862	0,068
2	0,225	0,367	0,142	21	0,944	0,866	0,078
3	0,346	0,516	0,17	22	0,952	0,87	0,082
4	0,445	0,6	0,155	23	0,959	0,874	0,085
5	0,497	0,655	0,158	24	0,966	0,878	0,088
6	0,547	0,694	0,147	25	0,971	0,881	0,09
7	0,596	0,724	0,128	26	0,975	0,884	0,091
8	0,639	0,747	0,108	27	0,979	0,887	0,092
9	0,677	0,766	0,089	28	0,983	0,889	0,094
10	0,709	0,782	0,073	29	0,987	0,892	0,095
11	0,736	0,795	0,059	30	0,99	0,894	0,096
12	0,76	0,806	0,046	31	0,994	0,897	0,097
13	0,785	0,816	0,031	32	0,995	0,899	0,096
14	0,81	0,825	0,015	33	0,996	0,901	0,095
15	0,833	0,833	0	34	0,997	0,903	0,094
16	0,856	0,84	0,016	35	0,998	0,905	0,093
17	0,877	0,846	0,031	36	0,998	0,906	0,092
18	0,896	0,852	0,044	37	0,999	0,908	0,091
19	0,915	0,857	0,058	38	1	0,91	0,09

При решении многих практических задач для уровня значимости  $\alpha$  обычно используют стандартные значения:  $\alpha = 0,1$ ,  $\alpha = 0,05$ ,  $\alpha = 0,01$  [1, 8]. Из табл. 1 следует:

$$\left. \begin{array}{l} D_N < z_{1-\alpha} = 1,63 \text{ при } \alpha = 0,01; \\ D_N < z_{1-\alpha} = 1,36 \text{ при } \alpha = 0,05; \\ D_N < z_{1-\alpha} = 1,22 \text{ при } \alpha = 0,1. \end{array} \right\} \quad (5)$$

Полученные результаты позволяют сделать заключение, что при всех трех рекомендованных уровнях значимости нет основания отвергнуть принятую гипотезу о виде функции распределения — распределении Парето.

При необходимости можно построить доверительную область для теоретического распределения — с этой целью при выбранном уровне значимости ( $\alpha = 0,01$ ) вычисляют величину

$$D_N^* = \frac{z_{1-\alpha}}{\sqrt{N}} = \frac{1,63}{\sqrt{50}} = 0,231$$

и наносят на график доверительной области:

$$F_B(x) = F(x) + D_N^*, \quad F_H(x) = F(x) - D_N^*,$$

где  $F_B(x)$ ,  $F_H(x)$  — верхняя и нижняя границы доверительной области.

Нанесенная на графике (рис. 2) эмпирическая функция распределения  $\hat{F}(x_j)$  команд учебной ЭВМ не выходит за доверительные границы. Это позволяет сделать вывод, что проверка гипотезы о согласии теоретического и эмпирического распределений с помощью критерия Колмогорова прошла успешно.

Такой же подход был применен для микрокоманд с заданным числом испытаний  $N = 42$  (были рассмотрены 42 команды). Результаты расчетов значений эмпирической

$\hat{F}(x_j)$  и теоретической  $F(x_j)$  функций распределения и разности  $D_j$  представлены в табл. 3.




Рис. 2

Таблица 3

Случайная величина $x$	Значение функции $\hat{F}(x_j)$	Значение функции $F(x_j)$	Разность $D_j$	Случайная величина $x$	Значение функции $\hat{F}(x_j)$	Значение функции $F(x_j)$	Разность $D_j$
1	0	0	0	26	0,933	0,9	0,033
2	0,16	0,387	0,227	27	0,936	0,903	0,033
3	0,297	0,54	0,243	28	0,939	0,905	0,034
4	0,433	0,625	0,192	29	0,942	0,907	0,035
5	0,555	0,679	0,124	30	0,945	0,91	0,035
6	0,677	0,718	0,041	31	0,948	0,912	0,036
7	0,712	0,747	0,035	32	0,951	0,914	0,037
8	0,747	0,77	0,023	33	0,953	0,915	0,038
9	0,773	0,788	0,015	34	0,956	0,917	0,039
10	0,797	0,804	0,007	35	0,959	0,919	0,04
11	0,817	0,816	0,001	36	0,962	0,921	0,041
12	0,834	0,827	0,007	37	0,965	0,922	0,043
13	0,852	0,837	0,015	38	0,968	0,924	0,044
14	0,863	0,845	0,018	39	0,971	0,925	0,046
15	0,875	0,852	0,023	40	0,974	0,926	0,048
16	0,884	0,859	0,025	41	0,977	0,928	0,049
17	0,892	0,865	0,027	42	0,98	0,929	0,051
18	0,901	0,87	0,031	43	0,983	0,93	0,053
19	0,907	0,875	0,032	44	0,985	0,931	0,054
20	0,913	0,88	0,033	45	0,988	0,932	0,056
21	0,919	0,884	0,035	46	0,991	0,933	0,058
22	0,922	0,887	0,035	47	0,994	0,934	0,06
23	0,924	0,891	0,033	48	0,997	0,935	0,062
24	0,927	0,894	0,033	49	1	0,936	0,064
25	0,93	0,897	0,033	—	—	—	—

На основе табл. 3 по формулам (1), (2) получаем

$$D_{\max} = 0,243, \quad D_N = \sqrt{N} \cdot D_{\max} = \sqrt{42} \cdot 0,243 = 1,575.$$

Сравнение полученного значения  $D_N$  с числом  $z_{1-\alpha}$  при  $\alpha = 0,1$ ,  $\alpha = 0,05$ ,  $\alpha = 0,01$  — см. выражения (5) — позволяет сделать вывод, что при  $\alpha = 0,1$  и  $\alpha = 0,05$  эмпирическое распределение микрокоманд не согласуется с теоретическим распределением Парето, а при  $\alpha = 0,01$  гипотеза о согласии принимается.

Для  $\alpha = 0,01$  доверительные границы для теоретического распределения представлены на рис. 3. Нанесенная на графике эмпирическая функция  $\hat{F}(x_j)$  распределения микрокоманд учебной ЭВМ не выходит за доверительные границы. Таким образом, гипотеза о согласии теоретического и эмпирического распределений Парето принимается.




Рис. 3

Итак, вышеизложенное позволяет сделать следующие обобщающие выводы.

1. Гипотетическая статистическая модель в виде функции распределения Парето соответствует реальным практическим данным, полученным для количественного оценивания частоты использования машинных команд ЭВМ и реализующих их микрокоманд.

2. Кумулятивные кривые математически характеризуются функциями распределения Парето с параметрами  $x_m = 1$ ,  $k = 0,66$  для команд и  $x_m = 1$ ,  $k = 0,70$  для микрокоманд. При этом случайными величинами являются номера команд и микрокоманд, представляющие собой члены ряда натуральных чисел.

3. Анализ графиков теоретических и практических функций распределения позволяет осуществить выбор команд и микрокоманд, редко используемых при работе процессора. Исключение из системы команд редко используемых машинных инструкций позволяет упростить состав и структуру устройств управления как аппаратного, так и микропрограммного типа процессоров ЭВМ.

Рассмотренные в статье отдельные теоретические положения и полученные практические результаты являются развитием представленного в работах [5, 8] статистического метода повышения качества — анализа Парето применительно к количественному оцениванию метрик машинных команд и микрокоманд ЭВМ.

#### СПИСОК ЛИТЕРАТУРЫ

1. Шуленин В. П. Математическая статистика. Ч. 1. Параметрическая статистика: Учебник. Томск: Изд-во НТЛ, 2012. 540 с.
2. Голяков А. Д., Миронов В. И., Смирнов В. В. Испытания систем ракетно-космической техники. СПб: ВИКИ им. А. Ф. Можайского, 1992. 398 с.
3. Басыров А. Г. Организация ЭВМ и систем: Практикум. СПб: ВКА им. А. Ф. Можайского, 2012. 83 с.
4. Жмакин А. П. Архитектура ЭВМ. СПб: БХВ-Петербург, 2010. 352 с.
5. Аверьянов А. В., Кошелев И. Н., Кузнецов В. В., Нгуен В. Т. Статистическое оценивание метрик машинных команд ЭВМ и реализующих их микрокоманд на основе анализа Парето // Изв. вузов. Приборостроение. 2023. Т. 66, № 4. С. 259—265.

6. Brunton S. L., Kutz J. N. Data-driven science and engineering : machine learning, dynamical systems, and control. Cambridge Univ. Press, 2019. 472 p.
7. Жадан В. Г. Методы оптимизации. Ч. II. Численные алгоритмы: Учеб. пособие. М.: МФТИ, 2015. 320 с.
8. Аверьянов А. В., Калюжный А. В. Применение анализа Парето для количественного оценивания частоты использования машинных команд ЭВМ // Изв. вузов. Приборостроение. 2019. Т. 62, № 2. С. 101—105.

#### *Сведения об авторах*

**Алексей Васильевич Аверьянов**

- канд. техн. наук, доцент; ВКА им. А. Ф. Можайского, кафедра информационно-вычислительных систем и сетей; преподаватель; E-mail: vka\_24kaf1@mail.ru
- ВКА им. А. Ф. Можайского, кафедра информационно-вычислительных систем и сетей; курсант; E-mail: vka\_24kaf1@mail.ru

**Van Tien Nguyen**

Поступила в редакцию 02.06.2023; одобрена после рецензирования 09.06.2023; принята к публикации 27.09.2023.

#### REFERENCES

1. Shulenin V.P. *Matematicheskaya statistika. Chast' 1. Parametricheskaya statistika* (Math Statistics. Part 1. Parametric Statistics), Tomsk, 2012, 540 p. (in Russ.)
2. Golyakov A.D., Mironov V.I., Smirnov V.V. *Ispytaniya sistem raketno-kosmicheskoy tekhniki* (Testing of Rocket and Space Technology Systems), St. Petersburg, 1992, 398 p. (in Russ.)
3. Basyrov A.G. *Organizatsiya EVM i sistem: praktikum* (Organization of Computers and Systems: Workshop), St. Petersburg, 2012, 83 p. (in Russ.)
4. Zhmakin A.P. *Arkhitektura EVM* (Computer Architecture), St. Petersburg, 2010, 352 p. (in Russ.)
5. Averyanov A.V., Koshel I.N., Kuznetsov V.V., Nguyen V.T. *Journal of Instrument Engineering*, 2023, no. 4(66), pp. 259–265. (in Russ.)
6. Brunton S.L., Kutz J.N. *Data-driven science and engineering: machine learning, dynamical systems, and control*, Cambridge, Cambridge University Press, 2019, 472 p.
7. Zhadan V.G. *Metody optimizatsii. Chast' 2. Chislennyye algoritmy* (Optimization Methods. Part 2. Numerical Algorithms), Moscow, 2015, 320 p. (in Russ.)
8. Averyanov A.V., Kalyuzhny A.V. *Journal of Instrument Engineering*, 2019, no. 2(62), pp. 101–105. (in Russ.)

#### *Data on authors*

**Alexey V. Averyanov**

- PhD, Associate Professor; A. F. Mozhaisky Military Space Academy, Department of Information Systems and Networks; Lecturer; E-mail: vka\_24kaf1@mail.ru

**Van Tien Nguyen**

- A. F. Mozhaisky Military Space Academy, Department of Information Systems and Networks; Student; E-mail: vka\_24kaf1@mail.ru

Received 02.06.2023; approved after reviewing 09.06.2023; accepted for publication 27.09.2023.

**ПРОГНОЗИРОВАНИЕ МУЛЬТИСЕЗОННЫХ НАГРУЗОЧНЫХ ПРОЦЕССОВ  
В ЭЛАСТИЧНЫХ ВЫЧИСЛИТЕЛЬНЫХ СИСТЕМАХ**

И. Г. МАРТЫНЧУК

Университет ИТМО, Санкт-Петербург, Россия  
*mt4.ilja@gmail.com*

**Аннотация.** Оценивается корректность применения метода мульти сезонной сезонно-трендовой декомпозиции на основе локально взвешенного сглаживания диаграммы рассеяния (MSTL) для задач прогнозирования мульти сезонных нагрузочных процессов в эластичных системах. Выполнен сравнительный анализ производительности и точности метода MSTL и сезонной интегрированной модели авторегрессионного скользящего среднего (SARIMA). Приведены результаты экспериментов, подтверждающие трудность построения модели SARIMA на данных с высокой степенью дискретизации и значениями периодов, превышающими классические сезонности, такие как 7, 12, 52. При построении модели SARIMA были наложены временные ограничения по подбору параметров вследствие высокого потребления памяти, что приводило к снижению точности прогноза и ограничению возможности построения модели на основе более высоких показателей сезонности. Метод MSTL демонстрирует преимущество по сравнению с моделью SARIMA по времени выполнения прогноза и потреблению памяти, однако на небольшом наборе исходных данных модель SARIMA показывает более высокую точность.

**Ключевые слова:** эластичные системы, мульти сезонные нагрузочные процессы, прогнозирование временных рядов, SARIMA, MSTL

**Ссылка для цитирования:** Мартынчук И. Г. Прогнозирование мульти сезонных нагрузочных процессов в эластичных вычислительных системах // Изв. вузов. Приборостроение. 2023. Т. 66, № 11. С. 907—916. DOI: 10.17586/0021-3454-2023-66-11-907-916.

**FORECASTING MULTI-SEASONAL LOAD PROCESSES IN ELASTIC COMPUTING SYSTEMS**

I. G. Martynchuk

ITMO University, St. Petersburg, Russia  
*mt4.ilja@gmail.com*

**Abstract.** The correctness of using the multi-seasonal season-trend decomposition method based on locally weighted scattergram smoothing for the problems of forecasting multi-seasonal load processes in elastic systems is assessed. A comparative analysis of the performance and accuracy of the above method and the seasonal integrated auto-regressive moving average (SARIMA) model is performed. Results of experiments are presented that confirm the difficulty of constructing the SARIMA model based on data with a high degree of discretization and period values exceeding classical seasonality, such as 7, 12, 52. When creating the SARIMA model, time restrictions are imposed on the selection of parameters due to high memory consumption, which lead to a decrease in forecast accuracy and limited the ability to build a model based on higher seasonality indicators. The multi-seasonal season-trend decomposition method demonstrates an advantage over the SARIMA model in terms of forecast execution time and memory consumption, however, with a small set of initial data, the SARIMA model shows higher accuracy.

**Keywords:** elastic systems, multi-seasonal workload, time series forecasting, SARIMA, MSTL

**For citation:** Martynchuk I. G. Forecasting multi-seasonal load processes in elastic computing systems. *Journal of Instrument Engineering*. 2023. Vol. 66, N 11. P. 907—916 (in Russian). DOI: 10.17586/0021-3454-2023-66-11-907-916.

**Введение.** Потоком пользовательских запросов к эластичной системе формируется некий нагрузочный процесс, для обработки которого необходимо определенное количество вычислительных ресурсов. Различное поведение пользователей приводит к различиям в

нагрузочных процессах, что усложняет проектирование и управление системой, так как отсутствует возможность применения единого шаблона нагрузочного процесса [1]. Естественное поведение пользователей, связанное, например, с их суточной активностью, приводит к возрастанию или убыванию количества запросов в единицу времени. Чтобы адаптироваться к таким изменениям в нагрузочном процессе, система должна обладать свойством масштабируемости, т. е. возможностью добавления или исключения вычислительных мощностей в соответствии с изменениями потока пользовательских запросов [2].

В настоящее время широко применяются два способа масштабирования: вертикальное и горизонтальное [3]. Вертикальное масштабирование основано на наращивании вычислительной мощности конкретного узла системы. Горизонтальное масштабирование заключается в наращивании числа вычислительных узлов при повышении нагрузки. Процесс масштабирования может быть частично или полностью реализован в автоматическом режиме. Такой процесс называется автоматическим масштабированием. Система, обладающая свойством автоматической горизонтальной масштабируемости, называется эластичной системой. В современных эластичных системах с открытым исходным кодом применяется простой метод автоматического масштабирования, основанный на использовании мгновенных данных по нагрузке [4]. Главным недостатком такого подхода является отсутствие возможности заблаговременного реагирования на изменения нагрузочного процесса.

Таким образом, важной задачей в современных эластичных системах является прогнозирование нагрузочных процессов с целью сохранения уровня качества предоставляемых услуг и снижения совокупной стоимости владения вычислительной инфраструктурой.

**Обзор исследований. Постановка задачи.** Суточная активность реальных пользователей по-разному влияет на характеристики нагрузочных процессов. Например, если обратиться к графикам суммарного транзитного трафика через узлы MSK-IX за неделю и месяц, то можно отметить ярко выраженную суточную периодичность нагрузочного процесса [5]. В теории временных рядов такая периодичность называется сезонностью. Для MSK-IX нагрузочный процесс имеет одну сезонную суточную составляющую.

Нагрузочные процессы в транзитных узлах на сетевом уровне отличаются от нагрузочных процессов, характерных для отдельных эластичных систем на прикладном уровне. На рис. 1 изображен нагрузочный процесс, представляющий собой агрегированное по пятиминутным интервалам число запросов ( $N$ ) к кластеру моделей машинного обучения, выполняющему прогнозы различных финансовых показателей в крупной коммерческой организации. Период наблюдения — один месяц. Видно, что представленный нагрузочный процесс имеет две сезонные составляющие: суточную и недельную. Такой порядок объясняется пятидневной рабочей неделей, характерной для крупных коммерческих организаций.




Рис. 1

В открытых источниках существует ряд работ, посвященных прогнозированию нагрузочных процессов в эластичных системах. В работах [6—8] рассматриваются прогнозы, осуществляемые с помощью линейных моделей регрессии, а именно авторегрессии и скользящего среднего (AR, MA, ARMA). В [8] используется также интегрированная модель линейной регрессии (ARIMA), позволяющая осуществить переход от нестационарного временного ряда к стационарному. В [9] применяются скрытые цепи Маркова для прогнозирования загрузки

виртуальных машин и последующего их размещения. Данные подходы не учитывают возможную сезонность в исследуемых нагрузочных процессах.

Для учета сезонности поступления данных используются модели SARIMA и SARIMAX [10]. В [11] показано, что такие модели демонстрируют сравнимые с нейронным сетями показатели точности прогноза. Однако сезонные модели ARIMA используют предположение только об одной сезонной составляющей и исследуемом временном ряде.

В области прогнозирования временных рядов существует ряд моделей и методов для работы с мульти сезонностью. В [12] показано применение моделей BATS и TBATS для работы с временными рядами, обладающими несколькими сезонными компонентами. В [13] для тех же целей предложено использовать библиотеку Prophet. Метод M STL, демонстрирующий уменьшение времени выполнения прогноза по сравнению с моделями BATS и TBATS, а также фреймворком Prophet, предложен в [14].

В открытых источниках не найдено работ, посвященных использованию метода мульти сезонной сезонно-трендовой декомпозиции на основе локально взвешенного сглаживания диаграммы рассеяния (M STL — Multiple Trend Decomposition Using LOWESS) для работы с временными рядами, которые формируются системами мониторинга эластичных систем. В связи с этим представляется актуальным исследование возможности использования метода M STL и сравнительный анализ его производительности и сезонной интегрированной модели авторегрессионного скользящего среднего (SARIMA — Seasonal Autoregressive Integrated Moving Average) для решения задач исследования и прогнозирования мульти сезонных нагрузочных процессов в эластичных вычислительных системах.

**Сезонная регрессионная модель случайных процессов.** В задачах прогнозирования временных параметров в эластичных системах случайный процесс — это интенсивность поступления пользовательских запросов, а также события, возникающие в системе после поступления очередного запроса. Такие процессы фиксируются с помощью систем мониторинга. На выходе случайный процесс представляет собой временной ряд. Поскольку при обработке случайных процессов используются их реализаций в виде временных рядов, понятия случайного процесса и временного ряда будем считать взаимозаменяемыми.

Для описания стационарных случайных процессов применяются линейные модели регрессии. Случайный процесс называется стационарным, если выполняется следующий набор условий [15]:

- математическое ожидание  $E$  не зависит от времени; временной ряд не имеет тенденции к росту или убыванию, а остается на одном уровне в течение всего периода наблюдений;
- дисперсия  $\sigma$  не зависит от времени; амплитуды колебаний временного ряда одинаковые вне зависимости от сдвига во времени;
- сила линейной связи между двумя величинами зависит только от расстояния между ними, т.е. автоковариационная и автокорреляционные функции зависят только от величины сдвига.

**Модель скользящего среднего порядка  $q$**  определяет состояние случайного процесса на основе взвешенного среднего  $q$  предыдущих значений белого шума:

$$\text{MA}(X_t, q) = \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q X_{t-q},$$

где  $X_t$  — состояние случайного процесса в момент времени  $t$ ;  $q$  — порядок модели;  $\varepsilon_t$  — белый шум с нулевым математическим ожиданием;  $\theta_i$  — весовой коэффициент.

Порядок модели определяется с помощью автокорреляционной функции, которая показывает степень линейной статистической зависимости между исходным рядом и его копией, сдвинутой на заданное число интервалов. Для модели MA( $q$ ) автокорреляционная функция затухает экспоненциально при сдвиге, превышающем порядок модели  $q$ .

**Авторегрессионная модель порядка  $p$**  определяет состояние случайного процесса на основе линейной комбинации  $p$  его предшествующих значений и белого шума:

$$\text{AR}(X_t, p) = \varepsilon_t + \alpha_1 X_{t-1} + \alpha_2 X_{t-2} + \dots + \alpha_p X_{t-p},$$

где  $p$  — порядок модели,  $\alpha_i$  — коэффициенты модели.

Порядок модели определяется функцией частной автокорреляции, позволяющей, как и в случае обычной автокорреляции, оценить характеристику взаимосвязей между предыдущими и текущими значениями временного ряда. Влияние малой задержки при этом устранено, так как частная автокорреляция направлена на исключение косвенной корреляции путем удаления линейной зависимости между сдвинутыми рядами. Для модели  $\text{AR}(p)$  частная автокорреляционная функция затухает экспоненциально при сдвиге, превышающим порядок модели  $p$ .

**Модель авторегрессионного скользящего среднего** состоит из комбинации моделей процессов  $\text{AR}(p)$  и  $\text{MA}(q)$ :

$$\text{ARMA}(X_t, p, q) = \varepsilon_t + \sum_{i=1}^p \alpha_i X_{t-i} + \sum_{i=1}^q \theta_i \varepsilon_{t-i}.$$

В случае процесса  $\text{ARMA}(p, q)$  автокорреляционная и частная автокорреляционная функции, начиная с некоторого сдвига, представляют собой сумму затухающих экспонент, если ряд стационарен. С помощью величины данного сдвига определяются порядки моделей  $\text{AR}(p)$  и  $\text{MA}(q)$ . Согласно теореме Вольда любой стационарный временной ряд может быть представлен с помощью модели  $\text{ARMA}(p, q)$  с любой точностью [16].

Во временных рядах обычно выделяют важные для понятия стационарности компоненты: тренд и сезонность. Трендом называется плавное долгосрочное изменение уровня ряда. Это приводит к изменению математического ожидания временного ряда, что делает ряд нестационарным. Сезонность представляет собой циклические изменения среднего значения ряда с постоянным периодом. Такие изменения могут затрагивать как математическое ожидание, так и дисперсию ряда, делая его также нестационарным.

**Интегрированная модель авторегрессионного скользящего среднего ( $\text{ARIMA}(p, d, q)$ )** представляет собой расширение модели  $\text{ARMA}(p, q)$  и содержит интегрированную составляющую:

$$\text{ARIMA}(X_t, p, d, q) = \varepsilon_t + \sum_{i=1}^p \alpha_i \Delta^d X_{t-i} + \sum_{i=1}^q \theta_i \varepsilon_{t-i},$$

где  $\Delta^d$  — оператор разности временного порядка  $d$ .

Данная составляющая позволяет перейти от нестационарного ряда к стационарному путем его дифференцирования  $d$  раз. Дифференцирование представляет собой переход от исходного временного ряда к ряду попарных разностей.

**Сезонная интегрированная модель авторегрессионного скользящего среднего ( $\text{SARIMA}$ )** является расширением модели ARIMA. Учет сезонности во временном ряду достигается путем добавления набора компонентов авторегрессии и скользящего среднего:

$$\text{SARIMA}(X_t, p, d, q, P, D, Q)_s = \varepsilon_t + \sum_{i=1}^p \alpha_i \Delta^d X_{t-i} + \sum_{i=1}^q \theta_i \varepsilon_{t-i} + \sum_{i=1}^P \beta_i \Delta^D X_{t-si} + \sum_{i=1}^Q \vartheta_i \varepsilon_{t-si},$$

где  $P$  — порядок сезонной авторегрессионной составляющей,  $D$  — порядок интегрирования сезонной составляющей,  $Q$  — порядок сезонной составляющей скользящего среднего,  $s$  — показатель сезонности;  $\beta_i$ ,  $\vartheta_i$  — коэффициенты сезонной составляющей.

### **Мульти сезонная сезонно-трендовая декомпозиция временного ряда.**

**Локально взвешенное сглаживание диаграммы рассеяния (LOWESS)** представляет собой механизм сглаживания на основе взвешенного скользящего среднего и взвешенной линейной или полиномиальной регрессии. Метод состоит из следующих операций.

1) Расчет расстояния между попарно распределенными точками исходного набора данных:

$$r(x_i, x_j) = |x_i - x_j|;$$

для каждой точки  $x_i$  определяются  $m$  смежных точек  $x_j$ , которые находятся ближе всего к  $x_i$ ; параметр  $m$  называется размахом или размером локального подынтервала.

2) Для каждой из  $m$  точек  $x_j$  в локальном подынтервале вычисляется масштабированная дистанция, где знаменатель содержит расстояние от точки  $x_i$  до наиболее удаленной точки  $x_j$  в локальном подынтервале:

$$r^*(x_j) = \frac{r(x_i, x_j)}{\max r(x_i, x_j)}.$$

3) Для каждой точки в локальном подынтервале рассчитывается вес следующим образом:

$$w(x_j) = \left(1 - [r^*(x_j)]^3\right)^3.$$

4) На основе точек в локальном подынтервале и полученных весов выполняется взвешенная линейная регрессия.

Результатом сглаживания в точке  $x_i$  является значение регрессии  $y = kx_i + b$ , где  $k$ ,  $b$  — параметры регрессии.

**Сезонно-трендовая декомпозиция временного ряда на основе LOWESS (STL)** используется для определения тренда и сезонной составляющей исследуемого временного ряда и состоит из внешнего и внутреннего циклов. Основные операции метода реализуются во внутреннем цикле, отвечающем за сглаживание сезонной и трендовой составляющих временного ряда. Внутренний цикл состоит из следующих операций.

1. Извлечение тренда из временного ряда; на первой итерации цикла этот шаг не выполняется.

2. Сглаживание сезонных подсерий; временной ряд разбивается на сезонные подсерии, каждая из которых сглаживается с помощью метода LOWESS.

3. Низкочастотная фильтрация сглаженных сезонных подсерий; сезонные подсерии суммируются и сглаживаются с помощью фильтров на основе скользящего среднего и LOWESS.

4. Извлечение трендовой составляющей из сезонных подсерий.

5. Извлечение из исходного временного ряда сезонной составляющей, полученной на предыдущих шагах.

6. Получение тренда путем сглаживания полученного на шаге 5 временного ряда с помощью LOWESS.

Внешний цикл отвечает за минимизацию влияния выбросов путем замены обычного метода LOWESS на его более устойчивую к большим отклонениям версию.

**Мульти сезонная сезонно-трендовая декомпозиция временного ряда на основе LOWESS (MSTL)** является расширением STL, позволяющим определять несколько сезонных компонентов во временном ряду. Метод состоит из следующих операций.

1. Извлечение каждой сезонной составляющей с помощью STL; сезонные составляющие сортируются по возрастанию периода для предотвращения возможного поглощения коротких сезонных циклов более длинными.

2. Определение тренда наиболее длинной сезонной составляющей (составляющей, извлеченной на заключительной итерации шага 1).

3. Определение остаточной составляющей путем извлечения тренда из полученного на шаге 2 временного ряда.

Если временной ряд не является сезонным, то для определения тренда используется алгоритм „Supersmooth“, разработанный Д. Фридманом и представляющий собой сглаживание двумерной регрессии на основе локальной линейной регрессии с адаптивной пропускной способностью [14].

**Эксперимент.** Для исследуемого временного ряда были выбраны данные, полученные системой мониторинга кластера моделей машинного обучения (см. рис. 1), обсуждаемые в постановке задачи. Взят отрезок наблюдения с июня по декабрь 2022 г. Пропуски в данных заполнены ближайшими следующими по порядку существующими отсчетами для корректной работы программных реализаций методов. Шаг наблюдений в исследуемом наборе данных равен 5 мин. Таким образом, дневной цикл равен 288 отсчетам, а недельный — 2016. Данные значения сезонности использовались в сравниваемых моделях.

В качестве модели SARIMA использована реализация *auto\_arima* библиотеки *pmdarima* языка Python. Для определения порядка дифференцирования регрессионной составляющей внутри модели использовался тест Квятковского — Филлипса — Шмидта — Шина. Определение порядка сезонности в автоматическом режиме осуществлялось на основе комбинации тестов OCSB и Кановы — Хансена. Показатель сезонности принимался и в качестве входного параметра. Для автоматического определения наилучшей модели использовался информационный критерий Акаике (AIC).

Для метода MSTL использована реализация библиотеки *statsforecast* языка Python, входной параметр — показатель сезонности.

Эксперименты проводились на тестовом стенде с установленным процессором AMD Ryzen 9 5950X и емкостью оперативной памяти 64 Гб. Запуск реализаций осуществлялся в окружении WSL2 под управлением ОС Windows 10.

Оценка качества прогноза выполнялась путем расчета следующих показателей:

- среднеквадратической ошибки

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (X_i - \hat{X}_i)^2},$$

где  $n$  — количество наблюдений в исследуемом наборе данных,  $X_i$  — фактическое значение, а  $\hat{X}_i$  — спрогнозированное значение временного ряда (набора данных); показатель RMSE совпадает с размерностью исходного набора данных;

- коэффициента детерминации:

$$R^2 = 1 - \frac{\sum_{i=1}^n (X_i - \hat{X}_i)^2}{\sum_{i=1}^n (X_i - \bar{X}_i)^2},$$

где  $\bar{X}_i$  — среднее значение временного ряда (набора данных); показатель представляет собой нормированную среднеквадратическую ошибку, чем ближе данный коэффициент к единице, тем выше качество прогноза.

**Результаты.** Рассчитанные показатели качества прогноза на один день вперед при построении моделей на недельных и месячных данных представлены в табл. 1.

Таблица 1

Показатель	SARIMA(0,1,0)(0,0,0)[288]		MSTL(288,2016)	
	Набор данных		Набор данных	
	недельный	месячный	недельный	месячный
RMSE	474,94404	—	2524,79448	711,03479
$R^2$	0,97192	—	0,206541	0,93902

Показатели производительности методов по результатам экспериментов представлены в табл. 2. Под временем выполнения понимается суммарное время, затраченное на построение модели и выполнение прогноза на день вперед.

Таблица 2

Метод	Недельный набор данных		Месячный набор данных	
	Время выполнения, с	Потребление памяти, Гб	Время выполнения, с	Потребление памяти, Гб
SARIMA	1080,92 ± 1,2	48,447 ОП 6,4 ± 0,4 swap	—	—
MSTL	6,48 ± 0,03	0,375 ± 0,025	15,23 ± 0,08	0,375 ± 0,025

Результаты прогноза на день вперед представлены на рис. 2: *a, б* — SARIMA и MSTL соответственно — недельные данные для построения модели; *в* — MSTL — заключительная неделя наблюдений для построения модели. В ходе экспериментов подтверждена высокая вычислительная сложность построения модели SARIMA на данных с высокой степенью дискретизации и значениями периодов, превышающими классические сезонности, такие как 7, 12 и 52. Для выбора подходящий модели SARIMA в автоматическом режиме было наложено мягкое ограничение на время построения модели, равное 5 мин. В противном случае ресурсов тестового стенда не хватало. При таких ограничениях алгоритмом по критерию AIC была выбрана модель SARIMA(0,1,0)(0,0,0)[288]. Прогноз выполнялся циклически на один пятиминутный интервал вперед с одновременным обновлением модели фактическими данными для повышения точности прогноза.

В случае недельного набора данных при прогнозе на день вперед модель SARIMA демонстрирует меньшее значение показателя RMSE и большее значение  $R^2$ , что свидетельствует о меньшей среднеквадратической ошибке прогноза. На месячных данных не удалось осуществить построение модели SARIMA, так как доступных ресурсов на тестовом стенде оказалось недостаточно.

Анализ табл. 2 показывает, что метод MSTL значительно превосходит SARIMA по скорости выполнения прогноза, а также по потреблению оперативной памяти и страниц swap.

Для метода MSTL также определена зависимость показателя  $R^2$  от величины исходного набора данных (количество недель —  $M$ ) при различных показателях сезонности (рис. 3). По результатам экспериментов можно сделать вывод, что точность прогноза при недельной сезонности выше, чем при мульти сезонном варианте. Это объясняется значительными различиями в нагрузке в выходные дни. Точность прогноза при небольшом количестве данных в исходном наборе приближается к точности прогноза при использовании модели SARIMA.




Рис. 2




Рис. 3

Основной целью процесса автоматизированного масштабирования является уменьшение затрат на вычислительную инфраструктуру. В контексте эластичных систем данная цель достигается путем снижения количества функционирующих вычислительных узлов в течение некоторого периода наблюдения. Согласно результатам экспериментов для построения модели SARIMA требуется значительное количество вычислительных ресурсов и времени в случае работы с временными рядами высокой степени дискретизации. Для данной модели необходим отдельный вычислительный узел со значительным количеством ресурсов, что снижает эффективность автоматического масштабирования, особенно в условиях частого перестроения моделей.

**Заключение.** По результатам исследования и прогнозирования мульти сезонных нагрузочных процессов, характерных для эластичных вычислительных систем, метод MSTL продемонстрировал преимущество по сравнению с моделью SARIMA по таким показателям, как время выполнения прогноза и потребление памяти.

На небольшом наборе исходных данных модель SARIMA демонстрирует более высокую точность по сравнению с методом MSTL в мульти сезонной конфигурации. При использовании же одной сезонной составляющей метод MSTL демонстрирует близкую к модели SARIMA точность на таком же наборе данных. Однако для построения модели SARIMA приходится накладывать ограничения по времени подбора параметров вследствие высокого потребления памяти, что ведет к снижению точности прогноза и ограничивает возможность построения модели на основе более высоких показателей сезонности.

## СПИСОК ЛИТЕРАТУРЫ

1. Aliev T. I., Rebezova M. I., Russ A. A. Statistical Methods for Monitoring Travel Agencies in the Settlement System // Automatic Control and Computer Sciences. 2015. Vol. 49, N 6. P. 321—327.
2. Bogatyrev V. A., Bogatyrev S. V., Bogatyrev A. V. Control of Multipath Transmissions in the Nodes of Switching Segments of Reserved Paths // Intern. Conf. on Information, Control, and Communication Technologies (ICCT), IEEE. 2022. P. 1—5.
3. Богатырев В. А., Богатырев С. В. Резервированная передача данных через агрегированные каналы в сети реального времени // Изв. вузов. Приборостроение. 2016. Т. 59, № 9. С. 735—740.
4. Portnoy M. Virtualization Essentials. John Wiley & Sons, 2012. Vol. 19.
5. АО „Центр взаимодействия компьютерных сетей «МСК-IX»“. Суммарный трафик участников, передаваемый через MSK-IX. [Электронный ресурс]: <https://www.msk-ix.ru/traffic/>, 15.07.2023.
6. Roy N., Dubey A., Gokhale A. Efficient autoscaling in the cloud using predictive models for workload forecasting // IEEE 4th Intern. Conf. on Cloud Computing. 2011. P. 500—507.
7. Tirado J. M. et al. Predictive data grouping and placement for cloud-based elastic server infrastructures // 11th IEEE/ACM Intern. Symp. on Cluster, Cloud and Grid Computing. 2011. P. 285—294.
8. Liao S. et al. Adaptive resource prediction in the cloud using linear stacking model // 5th Intern. Conf. on Advanced Cloud And Big Data (CBD). IEEE. 2017. P. 33—38.
9. Melhem S. B. et al. Markov prediction model for host load detection and VM placement in live migration // IEEE Access. 2017. Vol. 6. P. 7190—7205.
10. Yazdanian P., Sharifian S. Cloud workload prediction using convnet and stacked lstm // 4th Iranian Conf. on Signal Processing and Intelligent Systems (ICSPIS). IEEE. 2018. P. 83—87.
11. Vagropoulos S. I. et al. Comparison of SARIMAX, SARIMA, modified SARIMA and ANN-based models for short-term PV generation forecasting // IEEE Intern. Energy Conf. (ENERGYCON). 2016. P. 1—6.
12. Naim I., Mahara T., Idrisi A. R. Effective short-term forecasting for daily time series with complex seasonal patterns // Procedia Computer Science. 2018. Vol. 132. P. 1832—1841.
13. Xie T., Ding J. Forecasting with multiple seasonality // IEEE Intern. Conf. on Big Data (Big Data). 2020. P. 240—245.
14. Bandara K., Hyndman R. J., Bergmeir C. MSTL: A seasonal-trend decomposition algorithm for time series with multiple seasonal patterns // arXiv preprint arXiv:2107.13462. 2021.
15. Fryzlewicz P., Van Bellegem S., Von Sachs R. Forecasting non-stationary time series by wavelet process modelling // Annals of the Institute of Statistical Mathematics. 2003. Vol. 55, N 4. P. 737—764.
16. Antoni J., Randall R. B. Unsupervised noise cancellation for vibration signals: part I—evaluation of adaptive algorithms // Mechanical Systems and Signal Processing. 2004. Vol. 18, N 1. P. 89—101.

### *Сведения об авторе*

**Илья Геннадьевич Мартынчук**

— Университет ИТМО, кафедра вычислительной техники; преподаватель; E-mail: mt4.ilja@gmail.com

Поступила в редакцию 19.06.2023; одобрена после рецензирования 28.06.2023; принятая к публикации 27.09.2023.

**REFERENCES**

1. Aliev T.I., Rebezova M.I., Russ A.A. *Automatic Control and Computer Sciences*, 2015, no. 6(49), pp. 321–327.
2. Bogatyrev V.A., Bogatyrev S.V., Bogatyrev A.V. *2022 International Conference on Information, Control, and Communication Technologies (ICCT)*, 2022, pp. 1–5.
3. Bogatyrev V.A., Bogatyrev S.V. *Journal of Instrument Engineering*, 2016, no. 9(59), pp. 735–740. (in Russ.)
4. Portnoy M. *Virtualization essentials*, John Wiley & Sons, 2012, 336 p.
5. <https://www.msk-ix.ru/traffic/>. (in Russ.)
6. Roy N., Dubey A., Gokhale A. *2011 IEEE 4th International Conference on Cloud Computing*, 2011, pp. 500–507.
7. Tirado J.M. et al. *11th IEEE/ACM Intern. Symp. on Cluster, Cloud and Grid Computing*, 2011, pp. 285–294.
8. Liao S. et al. *5th Intern. Conf. on advanced cloud and big data (CBD)*, 2017, pp. 33–38.
9. Melhem S. B. et al. *IEEE Access*, 2017, vol. 6, pp. 7190–7205.
10. Yazdanian P., Sharifian S. *2018 4th Iranian Conf. on Signal Processing and Intelligent Systems (ICSPIS)*, 2018, pp. 83–87.
11. Vagropoulos S.I. et al. *2016 IEEE Intern. Energy Conf. (ENERGYCON)*, 2016, pp. 1–6.
12. Naim I., Mahara T., Idrisi A.R. *Procedia Computer Science*, 2018, vol. 132, pp. 1832–1841.
13. Xie T., Ding J. *2020 IEEE Intern. Conf. on Big Data (Big Data)*, 2020, pp. 240–245.
14. Bandara K., Hyndman R.J., Bergmeir C. *arXiv preprint arXiv:2107.13462*, 2021.
15. Fryzlewicz P., Van Bellegem S., Von Sachs R. *Annals of the Institute of Statistical Mathematics*, 2003, no. 4(55), pp. 737–764.
16. Antoni J., Randall R.B. *Mechanical Systems and Signal Processing*, 2004, no. 1(18), pp. 89–101.

**Data on author****Ilya G. Martynchuk**— ITMO University, Department of Computing Technique; Lecturer;  
E-mail: mt4.ilja@gmail.com

Received 19.06.2023; approved after reviewing 28.06.2023; accepted for publication 27.09.2023.

# СИСТЕМНЫЙ АНАЛИЗ, УПРАВЛЕНИЕ И ОБРАБОТКА ИНФОРМАЦИИ

## SYSTEM ANALYSIS, CONTROL, AND INFORMATION PROCESSING

УДК 65.011.56

DOI: 10.17586/0021-3454-2023-66-11-917-925

### МЕТОДИКА ОЦЕНИВАНИЯ СИСТЕМЫ ЭКСПЛУАТАЦИИ СЛОЖНЫХ ОБЪЕКТОВ НА ОСНОВЕ НЕЧЕТКО-ВОЗМОЖНОСТНОГО ПОДХОДА

А. В. СТОЛБОВ<sup>1</sup>, А. В. СПЕСИВЦЕВ<sup>2\*</sup> В. В. ЛИСИЦКИЙ<sup>1</sup>, В. А. СПЕСИВЦЕВ<sup>2</sup>

<sup>1</sup> Военно-космическая академия им. А. Ф. Можайского, Санкт-Петербург, Россия

<sup>2</sup> Санкт-Петербургский федеральный исследовательский центр РАН,

Санкт-Петербург, Россия

\*sav2050@gmail.com

**Аннотация.** Представлены результаты исследования по созданию методики оценивания системы эксплуатации сложных объектов на основе нечетко-возможностного подхода с использованием явных и неявных профессиональных экспертных знаний. Факторное пространство содержит семь нечетких лингвистических переменных для построения нечетко-возможностной математической модели оценивания состояния объектов наземной космической инфраструктуры, в качестве которых рассмотрена система космического слежения и наблюдения как сложный объект, а также исследована ее зависимость от качества функционирования соответствующей системы эксплуатации. Эффективность применения созданной методики оценивалась на основе расчетов с использованием построенной нечетко-возможностной модели.

**Ключевые слова:** система эксплуатации, сложный объект, явные и неявные экспертные знания, нечетко-возможностная модель

**Благодарности:** работа выполнена при частичной финансовой поддержке в рамках бюджетной темы FFZF-2022-0004.

**Ссылка для цитирования:** Столбов А. В., Спесивцев А. В., Лисицкий В. В., Спесивцев В. А. Методика оценивания системы эксплуатации сложных объектов на основе нечетко-возможностного подхода // Изв. вузов. Приборостроение. 2023. Т. 66, № 11. С. 917—925. DOI: 10.17586/0021-3454-2023-66-11-917-925.

### METHODOLOGY FOR ASSESSING THE OPERATION SYSTEM OF COMPLEX OBJECTS BASED ON THE FUZZY-POSSIBILITY APPROACH

A. V. Stolbov<sup>1</sup>, A. V. Spesivtsev<sup>2\*</sup> V. V. Lisitskiy<sup>1</sup>, V. A. Spesivtsev<sup>2</sup>

<sup>1</sup> A. F. Mozhaisky Military Space Academy, St. Petersburg, Russia

<sup>2</sup> St. Petersburg Federal Research Center of the RAS, St. Petersburg, Russia

\*sav2050@gmail.com

**Abstract.** Results of a study on creation of a methodology for assessing the operation system of complex object based on a fuzzy-possibility approach using explicit and implicit professional expert knowledge are presented. The factor space contains seven fuzzy linguistic variables for constructing a fuzzy-possibility mathematical model for assessing the state of objects of ground-based space infrastructure, in which the space tracking and surveillance system is considered as a complex object, and its dependence on the quality of functioning of the corresponding system is also studied. The effectiveness of the created methodology was assessed based on calculations using the constructed fuzzy-possibility model.

© Столбов А. В., Спесивцев А. В., Лисицкий В. В., Спесивцев В. А., 2023

**Keywords:** operating system, complex technical system, explicit and implicit expert knowledge, fuzzy-possibility model

**Acknowledgments:** the work was carried out with partial financial support within the framework of the budget theme FFZF-2022-0004.

**For citation:** Stolbov A. V., Spesivtsev A. V., Lisitskiy V. V., Spesivtsev V. A. Methodology for assessing the operation system of complex objects based on the fuzzy-possibility approach. *Journal of Instrument Engineering*. 2023. Vol. 66, N 11. P. 917—925 (in Russian). DOI: 10.17586/0021-3454-2023-66-11-917-925.

**Введение.** Тенденции развития современного высокотехнологичного общества привели к появлению и развитию разнообразных сложных объектов (СлО), эффективность и работоспособность которых зависит от качества и надежности множества взаимосвязанных элементов, входящих в их состав. Взаимодействие элементов СлО обеспечивается системой эксплуатации (СЭ) в соответствии с требованиями ГОСТ Р В 0101-001-2007. Традиционно СЭ, как правило, создаются под уже готовые СлО и их применение базируется на использовании известных методов статистического анализа. Однако достоверные данные о вероятностно-статистических характеристиках СЭ возможно получить только по репрезентативным выборкам в течение достаточно длительной эксплуатации, что связано с определенными трудностями, вызванными различием в целевом назначении СлО [1—5].

Качество функционирования СЭ СлО зависит от множества факторов, связанных с эксплуатацией, проектированием, влиянием внешней среды, обученностью обслуживающего персонала и его готовностью к выполнению задач эксплуатации системы. Так, применительно к системам наблюдения, используемым в космонавтике, независимо от назначения соответствующих СлО их СЭ характеризуется показателями, основные из которых приведены в табл. 1. Следует отметить, что значения данных показателей могут варьироваться в достаточно широком диапазоне.

Таблица 1

Показатель	Описание
Вероятность восстановления СлО в установленное время	Показатель надежности СлО, характеризующий ремонтопригодность как вероятность того, что время восстановления работоспособного состояния объекта не превысит заданного
Коэффициент технического использования СлО	Комплексный показатель надежности, рассчитываемый как отношение математического ожидания суммарного времени пребывания объекта в работоспособном состоянии в течение некоторого периода эксплуатации к математическому ожиданию суммарного времени пребывания объекта в работоспособном состоянии и в простоях, обусловленных техническим обслуживанием и ремонтом за тот же период
Коэффициент готовности СлО	Комплексный показатель надежности, рассчитываемый как вероятность того, что объект окажется в работоспособном состоянии в произвольный момент времени, кроме планируемых периодов времени, в течение которых применение по назначению не предусмотрено
Вероятность безотказной работы СлО	Комплексный показатель надежности, рассчитываемый как вероятность того, что объект будет сохранять параметры в заданных пределах в течение определенного времени и при определенных условиях эксплуатации
Коэффициент обеспеченности СлО	Комплексный показатель экономической эффективности функционирования СлО, характеризующий уровень обеспечения материально-техническими средствами, финансирования работ и оплаты деятельности обслуживающего персонала. Отражает отношение всех видов существующих запасов к их требуемому уровню, позволяет определить, способен ли СлО функционировать с заданными характеристиками при существующем уровне обеспечения и потребления

Продолжение табл. 1

Коэффициент готовности оператора к выполнению операций	Комплексный показатель качества подготовки обслуживающего СлО персонала, характеризующий способность к выполнению необходимых операций по поддержанию техники в работоспособном состоянии. Включает вероятности: своевременного выполнения работ, безошибочной работы, исправления допущенной ошибки
Коэффициент влияния внешней среды на СлО	Комплексный показатель, характеризующий влияние внешних факторов (климатических, техногенных, человеческих и др.) на безопасность и безаварийность функционирования СлО. Определяется как отношение времени простоев (неплатного функционирования) из-за внешних факторов к общему времени функционирования СлО в заданных параметрах

С учетом вышеизложенного для оценивания состояния функциональной пригодности конкретного варианта СЭ СлО необходимо создать математическую модель в виде следующей формулы [6]:

$$Y = Y(x_1, x_2, x_3, \dots, x_l), \quad (1)$$

где  $Y$  — обобщенный показатель качества функционирования оцениваемой СЭ СлО;  $x_1, x_2, x_3, \dots, x_l$  — переменные (частные показатели качества), в наибольшей степени влияющие на эффективность функционирования СЭ.

Следует отметить, что количественные значения перечисленных показателей определяются соответствующей эксплуатационной и/или другой регламентирующей документацией, а установленные нормативы, определяющие границы изменения данных частных показателей (параметров), носят рекомендательный характер и относятся ко всему множеству оцениваемых элементов без учета их конкретного состояния. При этом значения некоторых показателей определяются, как правило, экспертными комиссиями, что приводит к необходимости использования математического аппарата теории нечетких множеств и отношений. Следует отметить, что применение детерминированных математических методов обработки нечеткой многофакторной информации может в итоге привести на практике к существенной неточности и некорректности в принятии управленческих решений [6, 7].

С математической точки зрения подобные задачи оценивания состояния СЭ СлО относят к классу слабоструктурированных и трудноформализуемых, что требует для их решения применения специфических моделей и методов, например нечетко-возможностного подхода с привлечением явных и неявных экспертных знаний, когда эксперт выступает как агент (субъект) с присущей ему „интеллектуальной информационно-диагностической системой“ (ИИДС) [6—9].

Цель настоящей статьи — разработка методики построения и использования математической модели, описывающей такое свойство СЭ, как способность обеспечить качественное функционирование СлО с заданными характеристиками на основе нечетко-возможностного подхода.

**Методика оценивания состояния системы эксплуатации сложных объектов.** Предлагаемый нечетко-возможностный подход основан на методах формализации неявно заданных причинно-следственных связей с использованием явных и неявных экспертных знаний. Обработка такой информации заключается в последовательном выполнении этапов извлечения экспертных знаний и формализации их в виде аналитического выражения.

Методика построения нечетко-возможностной модели оценивания состояния СЭ СлО на основе явных и неявных экспертных знаний состоит из следующих шагов [9].

*Шаг 1.* Формулировка задачи, выбор и обоснование факторного пространства, в рамках которого будет приниматься решение о состоянии СЭ СлО, и построение вербально-числовых шкал для всех переменных, используемых в рамках выбранного факторного пространства.

*Шаг 2.* Представление выбранных переменных (характеристик) в виде лингвистических переменных с соответствующими шкалами измерений. Построение множества нечетких производственных правил импликативного типа „если..., то...“ как формы представления экспертиз знаний.

*Шаг 3.* Подготовка на основе методов теории планирования экспериментов опросной матрицы для выбранного факторного пространства и заполнение ее экспертом. Строки матрицы при этом формируются на основе нечетких производственных правил импликативного типа „ситуация — оценка“. На основе известных методик теории планирования экспериментов построение полиномиальной модели, описывающей такое свойство СЭ, как способность обеспечить качественное функционирование СЛО.

*Шаг 4.* Оценивание уровня корректности построенной модели и соответствующих модельных расчетов с использованием, во-первых, такого параметра, как степень близости обобщенного показателя вида (1) к его экспертными оценкам, и, во-вторых, показателя согласованности результатов нечетко-возможностного моделирования состояния СЭ СЛО с результатами оценивания фактического состояния СЭ СЛО на основе статистических данных или результатов специальных экспериментов.

*Шаг 5.* Проведение экспертом профессионального анализа построенной модели, извлечение методами математического анализа новой информации о специфике функционирования конкретной СЭ СЛО. Внесение предложений по использованию модели на практике применительно к функционированию объектов наземной космической инфраструктуры (ОНКИ) как базы знаний при создании соответствующей автоматизированной системы управления.

Проиллюстрируем конструктивность предложенной методики на конкретном примере.

Пусть на шагах 1 и 2 экспертом выбрано пространство из семи факторов (переменных, частных показателей), представленных в виде лингвистических переменных (табл. 2).

Таблица 2

Фактор	Лингвистические шкалы								
$X_1 = P_b(t)$ — вероятность восстановления СЛО в установленное время	H	H-HC	HC	HC-C	C	C-BC	BC	BC-B	B
$X_2 = K_{t,i}$ — коэффициент технического использования СЛО	H	H-HC	HC	HC-C	C	C-BC	BC	BC-B	B
$X_3 = K_g$ — коэффициент готовности СЛО	H	H-HC	HC	HC-C	C	C-BC	BC	BC-B	B
$X_4 = P(t)$ — вероятность безотказной работы СЛО	H	H-HC	HC	HC-C	C	C-BC	BC	BC-B	B

Продолжение табл. 2

$X_5 = K_{об}$ — коэффициент обеспеченности материально-техническими средствами	
$X_6 = K_{оп}$ — коэффициент готовности оператора	
$X_7 = K_{вн}$ — коэффициент влияния внешней среды	
$Y = K_{\mathcal{E}}$ — способность СЭ обеспечить функционирование СлО с заданными характеристиками	

Каждый из факторов (частных показателей), представленных лингвистической переменной, например  $X_1$ , содержит три шкалы перевода вербальных оценок эксперта в числовые значения: по оси абсцисс — верхняя вербальная (Н — низкая оценка, НС — ниже средней, С — среднее, ВС — выше средней, В — высокая) и две нижние — натуральные значения (интервал 0,85—0,99) и стандартизованные значения в интервале [−1, +1] для использования методик теории планирования экспериментов. По оси ординат — функция принадлежности в интервале [0,1], причем значения „1“ соответствуют модам лингвистических признаков.

Как следует из определения обобщенного показателя  $Y$ , оценивание каждого из возможных вариантов состояния СЭ переносится в область вербальных экспертных оценок ( $Y_{\text{эксп}}$ ) эффективности (качества) выполнения возлагаемых на СЭ функций на любом интервале жизненного цикла СлО.

На шаге 3 по выбранному факторному пространству создана специальная опросная матрица (табл. 3), строки которой представлены нечеткими продукционными правилами импликативного типа „если..., то...“ и являются вариантами запланированных ситуаций изменения значений лингвистических переменных. Все переменные в табл. 3, согласно методам теории планирования экспериментов, приведены в стандартизованном масштабе с интервалом изменения [−1,+1]. Стандартизация (кодирование) переменных осуществляется по формулам

$$x_i = \frac{X_i - \bar{X}_i}{\Delta X_i}, \quad \bar{X}_i = \frac{X_{\max} + X_{\min}}{2}, \quad \Delta X_i = \frac{X_{\max} - X_{\min}}{2}.$$

Процедура арифметизации вербальных оценок  $Y_{\text{эксп}}$  в табл. 3 по вербально-числовой шкале табл. 2 предоставляет возможность применения классических методов теории планирования экспериментов с построением полиномиальной модели [6, 7, 9].

Таблица 3

№ п/п	$x_1$	$x_2$	$x_3$	$x_4$	$x_5$	$x_6$	$x_7$	Экспертная оценка $Y_{\text{эксп}}$		Расчетное по модели значение $Y$
								верbalная	количественная	
1	-1	-1	-1	-1	-1	-1	1	H	0,85	0,84
2	1	-1	-1	-1	-1	-1	-1	HC	0,89	0,88
3	-1	1	-1	-1	-1	-1	-1	H-HC	0,87	0,86
4	1	1	-1	-1	-1	-1	1	C	0,92	0,91
...	...	...	...	...	...	...	...	...	...	...
61	-1	-1	1	1	1	1	1	C	0,92	0,92
62	1	-1	1	1	1	1	-1	BC	0,99	0,97
63	-1	1	1	1	1	1	-1	C-BC	0,94	0,95
64	1	1	1	1	1	1	1	B	0,99	0,99

Например, строка 3 матрицы читается так: если коэффициент вероятности восстановления ( $x_1$ ) „низкий“, и коэффициент технического использования ( $x_2$ ) „высокий“, и коэффициент готовности ( $x_3$ ) „низкий“, и вероятность безотказной работы ( $x_4$ ) „низкая“, и коэффициент обеспеченности ( $x_5$ ) „низкий“, и коэффициент готовности оператора ( $x_6$ ) „низкий“, и коэффициент влияния внешней среды ( $x_7$ ) „низкий“, то, по мнению эксперта, способность СЭ обеспечить функционирование СлО с заданными характеристиками находится между значениями „низкая“ и „ниже средней“ (H-HC). В числовом выражении мода этой оценки по шкале табл. 2 составляет 0,87.

В результате обработки численных данных табл. 3 получено полиномиальное выражение (требуемая математическая модель), связывающее такой обобщенный показатель СЭ, как  $Y$ , с семью базовыми характеристиками (частными показателями), представленными переменными в соответствующем факторном пространстве:

$$\begin{aligned} Y = & 0,91051 + 0,02168x_1 + 0,01348x_2 + 0,02098x_3 + 0,01074x_4 + 0,00965x_5 + \\ & + 0,00512x_6 + 0,00254x_7 + 0,00254x_2x_7 + 0,00293x_3x_5 + 0,00582x_4x_5 - \\ & - 0,00309x_1x_2x_6 - 0,00254x_1x_3x_7 + 0,00238x_2x_3x_7 - 0,00527x_3x_4x_5. \end{aligned} \quad (2)$$

В выражении (2) присутствуют члены разложения только со значимыми (отличными от нуля) коэффициентами при соответствующих независимых переменных, представленных в стандартизованном масштабе.

Мерой точности вычислений по модели, как правило, выбирают остаточную дисперсию или квадратный корень из нее  $s_{\text{oct}}$  — остаточное квадратическое отклонение, вычисленное по модели и характеризующее меру рассеяния точек вокруг линии тенденции, определяемой моделью  $Y$ . Применительно к данному примеру рассчитанное значение  $s_{\text{oct}}$  равно 0,01. Обычно  $s_{\text{oct}}$  сравнивается с мерой нечеткости экспертной информации  $s_{\text{эксп}}$ , которая в данном случае определяется как


$$s_{\text{эксп}} = \frac{\Delta Y}{2} = \frac{0,99 - 0,85}{4} = 0,035.$$

Выполнение неравенства

$$s_{\text{oct}} = 0,01 < s_{\text{эксп}} = 0,035 \quad (3)$$

свидетельствует о достаточной точности вычислений по построенной модели.

Оценка корректности вычислений по модели (2) проводится в два этапа: сначала на основе мнений экспертов, а затем на основе реальных данных, полученных в результате измерений компонент вектора состояния конкретных СЭ СлО. Так, на первом этапе обработанные мнения экспертов ( $Y_{\text{эксп}}$ ) о способности СЭ обеспечить функционирование СлО с заданными характеристиками иллюстрируются рисунком, где представлен график корреляции экспертных оценок и расчетных значений, полученных с использованием модели. Рассматриваемая связь оценивается коэффициентом корреляции  $R=0,97$ .



На втором этапе, вследствие отсутствия статистических данных по изучаемому явлению, степень адекватности расчетных значений модели (2) фактической способности СЭ обеспечить функционирование СлО с заданными характеристиками проверялась ситуационно на трех действующих СлО в ходе специального исследования, суть которого состояла в следующем. Для каждого СлО назначались группы экспертов, которые на основе ознакомления с нечетко-возможностным подходом производили вербальное оценивание СЭ по всему факторному пространству, включая и  $Y_\Phi$  — способность СЭ обеспечить функционирование СлО с заданными характеристиками.

Результаты исследований приведены в табл. 4, где вербальные экспертные оценки по всем переменным (верхние буквенные в каждой клетке) оценивались по описательным характеристикам табл. 2. Последующей арифметизацией вербальных оценок в численный вид (нижние значения в каждой клетке) и вычислением по модели (2) получены значения  $Y$ , которые по табл. 2 переводились в вербальные для сравнения с независимыми экспертными оценками  $Y_\Phi$ .

Таблица 4

Объект	$X_1$	$X_2$	$X_3$	$X_4$	$X_5$	$X_6$	$X_7$	$Y_\Phi$	$Y$
1	НС -0,5	С 0	ВС 0,75	Н -1	С 0	С-ВС 0,25	С 0	С <b>0,93</b>	<b>НС-С 0,916</b>
2	С 0	ВС 0,5	ВС 0,75	С-ВС 0,25	С 0	С-ВС 0,25	НС-С -0,25	С-ВС <b>0,93</b>	<b>С-ВС 0,934</b>
3	ВС-В 0,75	ВС-В 0,75	ВС 0,75	С-ВС 0,25	С-ВС 0,25	В 1	НС-С -0,25	<b>ВС-В 0,97</b>	<b>ВС 0,953</b>

Анализ табл. 4 показывает, что различие между вербальными оценками  $Y_\Phi$  и рассчитанными  $Y$  по модели (2) не превышает полшага исходной экспертной нечеткости по шкале табл. 2 и позволяет считать полученную модель адекватной фактическому состоянию СЭ.

Таким образом, оба предложенные в статье показателя — высокая степень корреляции между экспертными оценками и расчетными значениями по модели ( $R=0,97$ ) и фактическое состояние СЭ СлО по оценкам независимых экспертов — позволяют использовать полученную модель как ИИДС взамен обращения к экспертам по изучаемому явлению.

Анализируя результаты исследований, можно сделать вывод о более существенном влиянии надежностных показателей ( $X_1—X_4$ ) на способность СЭ обеспечить функционирование СлО с заданными характеристиками, в отличие от показателей готовности персонала, влияния окружающей среды и обеспеченности СлО материальными техническими средствами, что соответствует аналитическим выводам, представленным в [10].

**Заключение.** В результате исследования создана и подтверждена на практике методика построения математической модели оценивания способности СЭ обеспечить функционирование СлО с заданными характеристиками. Принципиальным отличием методики является

использование явных и неявных экспертных знаний, причем сам эксперт выступает в роли „интеллектуальной информационно-диагностической системы“.

На основе созданной методики в семифакторном пространстве построена нечетко-возможностная модель оценивания и прогнозирования способности СЭ обеспечить функционирование СлО с заданными характеристиками, позволяющая получать результаты в количественном виде.

Построенная модель наиболее востребована на стадии формирования СЭ ОНКИ. Вместе с тем применение модели возможно при построении СЭ большинства других СлО, для которых характерны приведенные выше показатели качества их функционирования.

#### СПИСОК ЛИТЕРАТУРЫ

1. Миронов А. Н., Лисицкий В. В., Столбов А. В. Математические основы решения многокритериальных оптимизационных задач синтеза сложных иерархических организационно-технических систем // Нелинейный мир. 2020. Т. 18, № 3. С. 5—17.
2. Анкудинов Г. И. Синтез структуры сложных объектов: Логико-комбинаторный подход. Л.: Изд-во ЛГУ, 1986. 260 с.
3. Павлов А. Н., Соколов Б. В. Формирование и совершенствование организационных структур управления. СПб: СПб ГУАП, 2005. 42 с.
4. Охтилев М. Ю., Соколов Б. В., Юсупов Р. М. Интеллектуальные технологии мониторинга и управления структурной динамикой сложных технических объектов М.: Наука, 2006. 410 с.
5. Ромеро И. Б. Измерение и анализ результативности и эффективности процессов // Все о качестве. 2000. № 22. С. 19—23.
6. Спесивцев А. В., Домщенко Н. Г. Эксперт как „интеллектуальная измерительно-диагностическая система“ // XIII Междунар. конф. по мягким вычислениям и измерениям SCM: Сб. докл., 23—25 июля 2010, Санкт-Петербург. 2010. Т. 2. С. 28—34.
7. Спесивцев А. В. Управление рисками чрезвычайных ситуаций на основе формализации экспертной информации / Под ред. проф. В. С. Артамонова. СПб: Изд-во Политехн. ун-та, 2004. 238 с.
8. Губанова Е. О. Неявное знание: сущность и виды // Знание. Понимание. Умение. 2010. № 4. С. 253—256.
9. Игнатьев М. Б., Марлей В. Е., Михайлов В. В., Спесивцев А. В. Моделирование слабо формализованных систем на основе явных и неявных экспертных знаний. СПб: Политех-Экспресс, 2018. 430 с.
10. Лисицкий В. В., Миронов А. Н. Метод решения многокритериальной оптимизационной задачи синтеза СЭ СТС в условиях нечеткой информации // Науч.-метод. сб. тр. науч.-техн. конф. „Перспективы развития и применения стратегических оборонительных систем“. 2019. Ч. 1. С. 127—138.

#### *Сведения об авторах*

**Александр Васильевич Столбов**

— аспирант; ВКА им. А. Ф. Можайского, 105 кафедра; преподаватель; E-mail: vka@mil.ru

**Александр Васильевич Спесивцев**

— д-р техн. наук; СПбФИЦ РАН, СПИИРАН, лаборатория информационных технологий в системном анализе и моделировании; ведущий научный сотрудник; E-mail: sav2050@gmail.com

**Владимир Вадимович Лисицкий**

— канд. техн. наук; ВКА им. А. Ф. Можайского, 81 кафедра; начальник кафедры; E-mail: vka@mil.ru

**Василий Александрович Спесивцев**

— СПбФИЦ РАН, Северо-Западный Центр междисциплинарных исследований проблем продовольственного обеспечения; младший научный сотрудник; E-mail: ryukuro@yandex.ru

Поступила в редакцию 28.06.2023; одобрена после рецензирования 07.07.2023; принятая к публикации 27.09.2023.

#### REFERENCES

1. Mironov A.N., Lisitskiy V.V., Stolbov A.V. *Nonlinear World*, 2020, no. 3(18), pp. 5–17. (in Russ.)
2. Ankudinov G.I. *Sintez struktury slozhnykh ob'yektorov: Logiko-kombinatornyy podkhod* (Synthesis of the Structure of Complex Objects: Logical-Combinatorial Approach), Leningrad, 1986, 260 p. (in Russ.)

3. Pavlov A.N., Sokolov B.V. *Formirovaniye i sovershenstvovaniye organizatsionnykh struktur upravleniya* (Formation and Improvement of Organizational Management Structures), St. Petersburg, 2005, 42 p. (in Russ.)
4. Okhtilev M.Yu., Sokolov B.V., Yusupov R.M. *Intellektual'nyye tekhnologii monitoringa i upravleniya strukturnoy dinamikoy slozhnykh ob'yektorov* (Intelligent Technologies for Monitoring and Controlling the Structural Dynamics of Complex Objects), Moscow, 2006, 410 p. (in Russ.)
5. Romero I.B. *Vse o kachestve*, 2000, no. 22, pp. 19–23. (in Russ.)
6. Spesivtsev A.V., Domshenko N.G. *XIII Mezhdunarodnaya konferentsiya po myagkim vychisleniyam i izmereniyam SCM* (XIII International Conference on Soft Computing and SCM Measurements), Collection of Papers, July 23–25, 2010, St. Petersburg, 2010, vol. 2, pp. 28–34. (in Russ.)
7. Spesivtsev A.V. *Upravleniye riskami chrezvychaynykh situatsiy na osnove formalizatsii ekspertnoy informatsii* (Emergency Risk Management Based on Formalization of Expert Information), St. Petersburg, 2004, 238 p. (in Russ.)
8. Gubanova E.O. *Knowledge. Understanding. Skill*, 2010, no. 4, pp. 253–256. (in Russ.)
9. Ignatiev M.B., Marley V.E., Mikhailov V.V., Spesivtsev A.V. *Modelirovaniye slaboformalizovannykh sistem na osnove yavnykh i neyavnykh ekspertynykh znanii* (Modeling Weakly Formalized Systems Based on Explicit and Implicit Expert Knowledge), St. Petersburg, 2018, 430 p. (in Russ.)
10. Lisitsky V.V., Mironov A.N. *Perspektivy razvitiya i primeneniya strategicheskikh oboronitel'nykh sistem* (Prospects for the Development and Application of Strategic Defensive Systems), Collection of Proceedings of the Scientific and Technical Conference, 2019, Part 1, pp. 127–138. (in Russ.)

**Data on authors**

- Aleksander V. Stolbov** — Post-Graduate Student; A. F. Mozhaisky Military Space Academy, Department 105; Lecturer; E-mail: vka@mil.ru
- Aleksander V. Spesivtsev** — Dr. Sci.; St. Petersburg Federal Research Center of the RAS, St. Petersburg Institute for Informatics and Automation of the RAS, Laboratory of Information Technologies in System Analysis and Modeling; Leading Researcher; E-mail: sav2050@gmail.com
- Vladimir V. Lisitskiy** — PhD; A. F. Mozhaisky Military Space Academy, Department 81; Head of the Department; E-mail: vka@mil.ru
- Vasiliy A. Spesivtsev** — St. Petersburg Federal Research Center of the RAS, North-West Center of Interdisciplinary Researches of Problems of Food Maintenance; Junior Researcher; E-mail: ryukuro@yandex.ru

Received 28.06.2023; approved after reviewing 07.07.2023; accepted for publication 27.09.2023

## REVIEW ON OPTIMIZATION TECHNIQUES OF BINARY NEURAL NETWORKS

A. SHAKKOUF

*ITMO University, St. Petersburg, Russia*  
*ashakkuf@itmo.ru*

**Abstract.** The deployment of Convolutional Neural Networks (CNNs) models on embedded systems faces multiple problems regarding computation power, power consumption and memory footprint. To solve these problems, a promising type of neural networks that uses 1-bit activations and weights emerged in 2016 called Binary Neural Networks (BNNs). BNN consumes less energy and computation power mainly because it replaces the complex heavy convolution operation with simple bitwise operations. However, the quantization from 32-float point to 1-bit leads to accuracy loss and poor performance, especially on large datasets. This article presents a review of the key optimization techniques which influenced the performance of BNNs and led to higher representation capacity of BNN models, as well as an overview of the application methods of BNNs in object detection tasks and compares the performance with the real value CNN.

**Keywords:** *binary neural networks, BNNs optimization, object detection, quantization, binarization, computer vision, artificial intelligence*

**For citation:** Shakkouf A. Review on Optimization Techniques of Binary Neural Networks. *Journal of Instrument Engineering*. 2023. Vol. 66, N 11. P. 926—935 (in English). DOI: 10.17586/0021-3454-2023-66-11-926-935.

## ОБЗОР МЕТОДОВ ОПТИМИЗАЦИИ БИНАРНЫХ НЕЙРОННЫХ СЕТЕЙ

А. Шаккуф

*Университет ИТМО, Санкт-Петербург, Россия*  
*ashakkuf@itmo.ru*

**Аннотация.** Разворачивание моделей сверточных нейронных сетей (СНС) во встраиваемых системах усложнено множеством проблем, связанных с вычислительной мощностью, энергопотреблением и объемом памяти. Для решения этих проблем в 2016 г. создан многообещающий тип нейронных сетей, использующих 1-битную активацию и веса, — бинарные нейронные сети (БНС). Такие сети потребляют меньше энергии и вычислительных мощностей, так как заменяют сложную операцию тяжелой свертки простыми побитовыми операциями. Однако квантование с 32-разрядной плавающей запятой до 1 бита приводит к потере точности и снижению производительности, особенно при больших наборах данных. Представлен обзор ключевых методов оптимизации, которые повлияли на производительность БНС и привели к повышению репрезентативности их моделей, также представлены обзор способов применения БНС в задачах обнаружения объектов и сравнительный анализ их производительности с реальным значением.

**Ключевые слова:** бинарные нейронные сети, оптимизация БНС, обнаружение объектов, квантование, бинаризация, компьютерное зрение, искусственный интеллект


**Ссылка для цитирования:** Шаккуф А. Обзор методов оптимизации бинарных нейронных сетей // Изв. вузов. Приборостроение. 2023. Т. 66, № 11. С. 926—935. DOI: 10.17586/0021-3454-2023-66-11-926-935.

**Introduction.** Convolutional Neural Networks (CNN) have pushed Artificial Intelligence (AI) limits in many aspects, including but not limited to image classification [1, 2], object recognition [3, 4], speech emotion recognition [4—6], object detection [7] and classification of noisy signals [8]. CNNs have heavy designs with massive computational costs and parameters size, which makes it difficult to deploy CNN on the edge and portable devices without model compressing techniques. One of compression techniques is quantization, in which network parameters are represented with data types of smaller size. The most severe quantization technique in binarization, in which weights and activations are represented using 1-bit and the resulting networks are called Binary Neural Net-

works (BNNs). BNNs represent the ideal class of neural network for edge inference especially for battery driven devices, due to their use of XNOR for multiplication: a fast and cheap operation to perform with much smaller times of memory accesses. Times of memory access is important because each hardware consumes certain amount of energy for each memory access [9]. Moreover, their parameters are 32x times more compact, which increases opportunities for caching, providing further potential performance boosts. However, binarization dramatically improves inference speed but accuracy is greatly affected. For example, binary connect network performs classification on CIFAR-10 dataset with accuracy 10% less than the accuracy of the real value network [10] and the loss in accuracy in much larger on largescale datasets such as ImageNet. Figure\* shows the great benefits of some BNN models in terms of models' sizes with acceptable inference latency. The loss in representation capacity of BNNs makes research for better binary feature maps representation -while training- a matter of central importance. Because of that, starting from 2016, a lot of research has been done to optimize BNNs and test its' performance in real applications. There are few reviews on BNNs, but our review is different from all other reviews in two points:

- we summarize the key optimization techniques that improved the performance of BNN to a large extent; other reviews summarize all the previously done research;

- we focus on works that use BNNs in object detection tasks and review all the previously conducted research in this field of computer vision.



**Key optimization techniques of BNNs.** Optimizing the training process of BNN is essential to gain the availability to train BNN on the edge. [11] provides a new low-cost strategy for BNN training that reduces the used memory by up to 5.44x while inducing little to no accuracy loss. Authors notice that high-precision activations should not be used while training BNNs, since we are only concerned with weights and activations' signs. Specifically, authors of [11] present the first successful combination of binary activations and binary and binary weight gradients during neural network training. An intuitive method to lower the memory footprint of training is to simply reduce the batch size. However, doing so generally leads to increased total training time due to reduced memory reuse [12]. The method in [11] does not conflict with batch size tuning, and further allows the use of large batches while remaining within the memory limits of edge devices. Authors used the standard BNNs training method of Courbariaux [10] as a baseline for comparison.

Authors in [10] introduce a method for training BNNs and perform two sets of experiments on two platforms: Torch7 and Theano. They operate on the binarizations approaches introduced by

\* Larq implementation of deep neural networks with extremely low precision weights and activations.

[13]. [13] introduces two approaches to transfer high-precision NNs to BNNs. The first approach is deterministic and the other one is stochastic. The deterministic approach is formulated as:

$$x^b = \text{sgn}(x) = \begin{cases} +1 & \text{if } x \geq 0, \\ -1 & \text{otherwise.} \end{cases}$$

Where  $x^b$  is the binarized value (weight or activation),  $x$  is the high-precision variable. While the stochastic approach is formulated as:

$$x^b = \begin{cases} +1 & \text{with probability } p = \sigma(x); \\ -1 & \text{with probability } 1 - p, \end{cases}$$

where  $\sigma$  is the hard sigmoid function;  $\sigma(x) = \text{clip}\left(\frac{x+1}{2}, 0, 1\right) = \max\left(0, \min\left(1, \frac{x+1}{2}\right)\right)$ .

Courbariaux [10] states that stochastic binarization is more appealing than the deterministic one, but harder to implement as it requires the hardware to have a random generation unit (peripheral). So, it is quite often preferable to use the deterministic approach over the stochastic one. The negative side of [10] is that real-valued gradients of the weights are accumulated in real-valued variables because they are required for Stochastic Gradient Descent (SGD) to work at all. However, this problem has been solved by [11]. The derivative of sign function is zero almost everywhere, and that prevent performing backpropagation. This problem has been solved by [14, 15], where the authors introduced what is called “straight-through estimator”. [10] uses the same approach as [14, 15] for gradient estimation but adds to it a saturation effect. Authors in [10] also wrote an optimized binary matrix multiplication kernel for GPU which performs 7x faster than the unoptimized GPU kernel.

It is well known that we add a regularization term like  $L_1$  and  $L_2$  to a model to prevent overfitting and as a result we obtain robust generalization. If we use these regularization functions while training binary NN, it will direct the weights to be near zero and this is not compatible with BNNs, because we need the weights to be around  $-1$  and  $+1$ . So, to make the regularization term more general, authors in [16] introduces scaling factor  $\alpha$  which makes the regularization function symmetric and has two minimums at  $-\alpha$ ,  $+\alpha$ . Those scales are embedded into the layers parameters and thus are learnable while training.

Authors in [17] provide a smart algorithm (framework) for automatic search of compact but accurate BNNs architecture. The main idea is to expand — while we binarize the network — each layer of the network by a factor of  $a$  where  $a \in \{0.25, 0.5, 1, 2, 3, 4\}$ . Specifically, authors create a generation of networks architectures, each architecture corresponds to an expansion ratio. After training, we choose the best candidate (best BNN architecture) using a fitness function  $f(a^k) = \max(\text{Acc} - \lambda \times \text{FLOPs}, 0)$  Where FLOPs and Acc are float operations and Top-1 validation accuracy of the network of an individual  $a^k$ ,  $\lambda$  is the trade-off parameter.

Applying x-nor and bit-count operations causes and accumulates notable quantization error, which usually results in inconsistent signs in binary feature maps compared with their full-precision counterpart [18]. To handle this inconsistency, [18] present a channel-wise interaction based binary convolutional neural network learning method (CI-BCNN) to learn BNN with channel-wise interactions to reduce the accumulated error and obtain an efficient inference. While in [19], authors approximate the real value weights with linear combination of multiple binary bases and use that to alleviate information loss in the forward pass. A network called Bi-Real proposed in [20] connects the float activations to activations of the consecutive block, through an identity shortcut. Conse-

quently, compared to the standard 1-bit CNN, the representational capability of the Bi-Real net is significantly enhanced.

Unlike [18], [21] proposes an approach that gives weights to binaries variables and is called Balanced Binary neural networks with Gated residual (BBG for short). First, weight-balanced binarization is presented so binary weights can capture more information contained in activations. Second, a gated residue is appended to make recompense for the loss of information during the forward pass, with a slight increase. Both techniques can be encapsulated as a generic network module that supports different network architectures for different tasks including detections. Authors assure deployment efficiency on mobile devices using a framework called daBNN and was introduced by [22].

According to central limit theorem (CLT) [23, 24], the general description for activation is that they are nearly Gaussian, which makes it hard for the  $\text{sign}(\cdot)$  function to capture the higher-order statistics such as variance. This fact motivated the authors of [25] to propose a new approach for binarization called „Sparsity-Inducing BNN“ (Si-BNN). The new approach tries to maximize the mutual information between inputs and outputs of a single layer by a proper (optimal) choosing of the sparsity threshold  $\theta$ . Binarization equation and backward gradient estimation via straight-through estimator (STE) formulas are:

$$X_b = \varphi(X) = \begin{cases} +1 & \text{if } x \geq \theta, \\ 0 & \text{otherwise;} \end{cases} \quad \frac{\partial \varphi}{\partial X} = \begin{cases} +1 & \text{if } 0 \geq X \geq +1, \\ 0 & \text{otherwise.} \end{cases}$$

Training Si-BNN and testing on ImageNet, MNIST and FICAR-10 benchmarks demonstrate that Si-BNN dramatically outperforms current best performing methods like QNet in [26] and BENN-6, Bagging in [27], lowering the performance gap between full-precision networks and binarized neural networks.

Compared to previous research that demonstrated the viability of BNNs via experiments, [28] explains why these BNNs work in terms of the High-Dimensional geometry. [28] shows that BNNs trained using the method of [10] work because of the high-dimensional geometry of binary vectors. In particular, the ideal continuous vectors that extract out features in the intermediate representations of these BNNs are well-approximated by binary vectors in the sense that dot products are approximately preserved. This theory serves as a foundation for understanding not only BNNs but a variety of methods that seek to compress traditional NNs using the well-known compression techniques mentioned in [29, 30]. A promising technique to enhance BNNs representation capacity introduced in [31] where authors refined the kernel and features using generative adversarial learning like KR-GAL and FR-GAL. [32] empirically proves that quantizing the weights can improve generalization, where authors show that eigenvalue of neural tangent kernel of the proposed network decays approximately exponentially.

**Application of BNNs in Object Detection.** Authors of [33] noticed that binarization leads to poor representation capabilities of features. To avoid that [34] proposes a method called “Block Scaling Factor XNOR” (BSF-XNOR). This method is built on the XNOR binarization algorithm [35] but adds to it better representation capabilities using a scaling factor for each block under a used filter and increasing in operation parallelization without increasing the calculation amount. The scaling factor is calculated using a specific mathematical expression introduced by [34]. The suggested algorithm was applied on unmanned aerial vehicles (drones). BSF-XNOR beats most of the well known algorithms for object detection in overall performance like XNOR, YOLOv3-tiny, Non-bin, XYLO [36].

To simplify the search for appropriate architecture of BNN, [37] proposes an algorithm called BNAS which produces high compact models for detection tasks. [38] presents a method for object detection in infrared images using BNNs. The authors demonstrate that the perfor-

mance of BNNs is very close to that of 32-bit floating-point networks on the IR dataset and present a system architecture (using external DRAM an internal SRAM) designed specifically for computation using binary representation. [38] shows that BNNs can achieve high recognition accuracy while reducing memory and energy requirements, making them suitable for use in embedded platforms and mobile devices. [39] proposes a new approach for object detection using a fast unified binary network. The proposed method is based on the X-NOR network and uses binary-precision convolution. The network also uses convolution kernels of different sizes to predict classes and bounding boxes of multi-scale objects directly which makes the approach easy to implement in embedded computing systems and achieves faster object detection with acceptable loss of accuracy.

A modified binarized convolutional neural network proposed in [40] can reduce power consumption without any speed loss and improve system performance while keeping low power dissipation. The article also describes the limitations of reducing power consumption through software and how optimized SoC hardware structure can extend the limitation of software methods, for example, by the use AXI interfaces to accelerate the process and optimize data transferring.

Authors in [41] propose a low bit-width weight optimization approach to train BNN called (BDNN). This method uses a greedy layer-wise technique to train the detection network instead of binarizing the whole network once at a time, which boosts performance instead of training the entire network at the same time.

To optimize the detection process for time, [42] introduces a point-process filter (PPF) that filters the input video stream to remove the noise. After that, the filtered images are passed to an efficiently implemented BNN on FPGA. The implementation shows a reduction of 86% in latency compared to the full precision NN.

[43] proposes a binarized neural network learning method called BiDet for efficient object detection. This method eliminates the redundant information using the principle of information bottleneck which gives us a fully utilization of the representational capacity of the networks and enforces the posteriors to be concentrated on informative prediction for false positive elimination, through which the detection precision is significantly enhanced.

To maintain a performance so close to that of real value NN, [44] presents a strategy called layer-wise searching which generates 1-bit detectors that minimize the angular error in a student-teacher framework. To increase the capacity of the detectors, authors introduce angular and amplitude loss functions. Those functions search learns the scale factor that minimizes the amplitude error and finds the optimal binary weights that minimize angular loss. On the other hand, authors in [45] try to increase features representation capacities by using an adaptive amplitude method that reformulates the binary convolution. A good comparison of the performance of different NNs in detection tasks was carried out by [46], where they compared previously trained CNN, QNN and BNN. The detection of small objects manipulated by hand was studied in [47] for surveillance purposes, where the authors implemented robust and reliable model for detection based on binarization techniques. A very actual detection task was studied by [48] which used BNN (DAD-Net) to detect drivable areas (segmentation) for autonomous driving which saves energy and computing power. The proposed network uses binary weights and activations in both encoder and encoder parts and in the bottleneck. To keep passengers safe in public transportation and alert for anomaly state, [49] implemented a BNN for faster emotion recognition from facial expressions. [50] performs semantic segmentation through GroupNet algorithm. GroupNet divides the network into sub-groups and performs approximation for each sub-group using combinations of binary bases. Table illustrates the BNN results of the object detection task on the benchmark datasets PASCAL VOC.

**Summary of BNNs performance on object detection for PASCAL VOC dataset**

<b>Neural Network Approach</b>	<b>Network Architecture</b>	<b>Binarization method / Real-valued</b>	<b>Trained Dataset</b>	<b>mAP%</b>
Customized	VGG16	Real-valued	VOC2007	68.9
		BNN	VOC2007	47.3
	Alexnet	Real-valued	VOC2007	66.0
		BNN	VOC2007	46.4
Faster RCNN	VGG16	BDNN	VOC2012	62.6
	ResNet-18	Real-valued	VOC2007	67.8
		Bi-Real Net	VOC2007	51.0
	ResNet-18	Real-valued	VOC2007+2012	73.2
		Bi-Real Net	VOC2007+2012	60.6
	ResNet-34	Real-valued	VOC2007+2012	75.6
		XNOR-Net	VOC2007+2012	54.7
	ResNet-18	Real-valued	VOC2007+2012	74.5
		BiDet	VOC2007+2012	50.0
		BiDet(SC)		59.5
		XNOR-Net		48.4
	ResNet-18	Bi-Real Net	VOC2007+2012	60.9
		BiDet		62.7
	ResNet-34	Real-valued	VOC2007+2012	77.8
		Bi-Real Net	VOC2007+2012	63.1
	ResNet-50	BiDet		65.8
		Real-valued	VOC2007+2012	79.5
	ResNet-18	Bi-Real Net	VOC2007+2012	65.7
		DA-BNN	VOC2007	74.5
YOLOv2	DarkNet	XNOR-Net	VOC2007	79.6
SSD	VGG16	BDNN	VOC2007+2012	63.3
		XNOR-Net		60.71
SSD300	VGG16	Real-valued	VOC2007+2012	72.4
		BiDet	VOC2007+2012	52.4
		BiDet(SC)		66.0
		XNOR-Net		50.2
	MobileNetV1	Bi-Real Net		63.8
		Real-valued	VOC2007+2012	68.0
	VGG16	BiDet	VOC2007+2012	51.2
		XNOR-Net		48.9
	VGG16	Real-valued	VOC2007+2012	74.3
		Bi-Real Net	VOC2007+2012	63.8
		BiDet		66.0

**Conclusion.** Although BNNs have some aspects to be used in, a few challenges and constraints remain an open issue for research. For a given task, what is the architecture of BNN we should use? In general, all the layers (except the input and output layers) of a BNN are binarized CNN layers, and this is a primary source for information loss. The deeper the BNN the more we lose information because the performance drop is accumulated from the previous layers. In this paper, we conducted a review on the key optimization techniques for BNN (training strategies, binarization methods, increasing representation capacity) and a review of the application and real-life tasks that used BNNs to handle object detections.

## REFERENCES

1. Basha S.S., Dubey S.R., Pulabaigari V., and Mukherjee S. *Neurocomputing*, 2020, vol. 378, pp. 112–119.
2. Zhou W., Wang H., and Wan Z. *Computers and Electrical Engineering*, 2022, vol. 99, art. no. 107819.
3. Gao X., Xing G., Roy S., and Liu H. *RIEEE Sensors J.*, 2021, no. 4(21), pp. 5119–5132.
4. Ashiq F., Asif M., Ahmad M. B., Zafar S., Masood K., Mahmood T., Mahmood M.T., and Lee I.H. *IEEE Access*, 2022, vol. 10, pp. 14819–14834.
5. Abdelhamid A.A., El-Kenawy E.-S.-M., Alotaibi B., Amer G.M., Abdelkader M.Y., Ibrahim A., and Eid M.M. *IEEE Access*, 2022, vol. 10, pp. 49265–49284.
6. Kwon S. *Expert Systems with Applications*, 2021, vol. 167, art. no. 114177.
7. Zhang N., Wei X., Chen H., and Liu W. *Electronics*, 2021, vol. 10, no. 3, p. 282.
8. Lopac N., Hrzic F., Vuksanovic I.P., and Lerga J. *IEEE Access*, 2022, vol. 10, pp. 2408–2428.
9. Horowitz M. *IEEE Intern. Solid State Circuits Conf.*, 2014, pp. 10–14.
10. Courbariaux M. and Bengio Y. *ArXiv journal*, 2016, preprint arXiv: 1602.02830.
11. Wang E., Davis J.J., Moro D., Zielinski P., Lim J.J., Coelho C., Chatterjee S., Cheung P.Y., Constantinides G.A. *ACM Transactions on Embedded Computing Systems*, 2021, DOI:10.1145/3626100.
12. Sohoni N.S., Aberger C.R., Leszczynski M., Zhang J., and Ré C. *ArXiv journal*, 2019, preprint arXiv:1904.10631.
13. Courbariaux M., Bengio Y., and David J.-P. *ArXiv e-prints*, 2015, abs/1511.00363.
14. Hinton G. *Neural networks for machine learning*, Coursera, video lectures, 2012.
15. Bengio Y. *Technical Report*, Universite de Montreal, arXiv:1305.2982, 2013.
16. Darabi S., Belbahri M., Courbariaux M., and Nia V.P. *BNN+: Improved binary network training*, 2019, <https://openreview.net/pdf?id=SJFHg2A5tQ>.
17. Shen M., Han K., Xu C., Wang Y. *IEEE/CVF Intern. Conf. on Computer Vision Workshops*, 2019.
18. Wang Z., Lu J., Tao C., Zhou J., Tian Q. *IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2019, vol. 568.
19. Lin X., Zhao C., and Pan W. *NIPS*, 2017, pp. 344–352.
20. Liu Z., Wu B., Luo W., Yang X., Liu W., and Cheng K.-T. *arXiv preprint*, 2018, arXiv:1808.00278.
21. Shen M., Liu X., Gong R., Han K. *IEEE Intern. Conf. on Acoustics, Speech and Signal Processing (ICASSP)*, 2020, vol. 4197.
22. Jianhao Zhang, Yingwei Pan, Ting Yao, He Zhao, and Tao Mei. *arXiv preprint*, 2019, arXiv:1908.05858.
23. Cai Z., He X., Sun J., and Vasconcelos N. *IEEE Conf. on Computer Vision and Pattern Recognition (CVPR)*, 2017.
24. Ioffe S., and Szegedy C. *Proc. of the 32nd Intern. Conf. on Machine Learning, ICML*, 2015, pp. 448–456.
25. Wang P., He X., Li G., Zhao T., Cheng J. *AAAI Conf. on Artificial Intelligence*, 2020, vol.34, pp. 12192.
26. Yang J., Shen X., Xing J., Tian X., Li H., Deng B., Huang J., and Hua X.-S. *IEEE Conf. on Computer Vision and Pattern Recognition (CVPR)*, 2019.
27. Zhu S., Dong X., and Su H. *IEEE Conf. on Computer Vision and Pattern Recognition (CVPR)*, 2019.
28. Anderson A.G. & Berg C.P. *ArXiv journal*, 2017, abs/1705.07199.
29. Qin H., Gong R., Liu X., Bai X., Song J., Sebe N. *Pattern Recognition*, 2020, 105. 107281. 10.1016/j.patcog.107281.
30. Liang T., Glossner J., Wang L., Shi S., and Zhang X. *Neurocomputing*, 2021, vol. 461, pp. 370–403.
31. Xu Sh., Liu Ch., Zhang B., Lu J., Guo G., Doermann D. *ACM Transactions on Multimedia Computing, Communications, and Applications*, 2022, 18. 10.1145/3473340.
32. Zhang K., Yin M., & Wang Y. *ArXiv journal*, 2022, abs/2206.05916.
33. Darabi S., Belbahri M., Courbariaux M., and Nia V.P. *ArXiv journal*, 2018, 1812.11800.
34. Wang S., Zhang C., Su D., Wang L., Jiang H. *IEEE Access* 9, 2021, pp. 106169.
35. Rastegari M., Ordóñez V., Redmon J., and Farhadi A. *ECCV*, 2016, pp. 525– 542.
36. Barry D., Shah M., Keijsers M., Khan H., and Hopman B. *ArXiv journal*: 1910.03159, 2019.
37. Chen H., Zhuo L., Zhang B., Zheng X., Liu J., Ji R., Doermann D., Guo G. *ArXiv journal*, 2020.
38. Kung J., Zhang D., van der Wal G., Chai S., Mukhopadhyay S. *Journal of Signal Processing Systems*, 2018, vol. 90, pp. 1–14, DOI: 10.1007/s11265-017-1255-5.
39. Wang X., Siyang S., Yin Y., Xu D. & Wu W., Gu Q. *CAAI Transactions on Intelligence Technology*, 2018, no. 3(4), DOI:10.1049/trit.2018.1026.
40. Kim H. and Choi K. *Intern. Conf. Internet Things (iThings) IEEE Green Comput. Commun. (GreenCom) IEEE Cyber, Phys. Social Comput. (CPSCom) IEEE Smart Data (SmartData)*, 2019, pp. 240–243.
41. Peng H. and Chen S. *Pattern Recognit. Lett.*, 2019, vol. 125, pp. 91–97.
42. Ojeda F.C., Bisulco A., Kepple D., Isler V., and Lee D.D. *Intern. Conf. Image Process. (ICIP)*, 2020, pp. 3084–3088.
43. Wang Z., Wu Z., Lu J., and Zhou J. *IEEE/CVF Conf. Comput. Vis. Pattern Recognit.*, 2020, pp. 2049–2058.
44. Xu S., Zhao J., Lu J., Zhang B., Han S., and Doermann D. *IEEE/CVF Conf. Comput. Vis. Pattern Recognit. (CVPR)*, 2021, pp. 5682–5691.
45. Zhao J., Xu S., Wang R., Zhang B., Guo G., Doermann D., and Sun D. *Pattern Recognit. Lett.*, 2022, vol. 153, pp. 239–245.
46. Mani V.R.S., Saravanaselvan A., and Arumugam N. *J. Microelectron.*, 2022, vol. 119, art. no. 105319.
47. Pérez-Hernández F., Tabik S., Lamas A., Olmos R., Fujita H., Herrera F. *Knowl. Base Syst.*, 2020, art. no.105590, <https://doi.org/10.1016/j.knosys.2020.105590>.
48. Frickenstein A., Vemparala M.-R., Mayr J., Nagaraja N.-S., Unger C., Tombari F., and Stechle W. *IEEE Intern. Conf. Robot. Autom. (ICRA)*, 2020, pp. 2295–2301.
49. Ajay B.S. and Rao M. *34th Intern. Conf. VLSI Design; 20th Intern. Conf. Embedded Syst. (VLSID)*, 2021, pp. 175–180.
50. Zhuang B., Shen C., Tan M., Liu L., and Reid I. *IEEE/CVF Conf. on Computer Vision and Pattern Recognition (CVPR)*, 2019, pp. 413–422.

**Data on author**

**Ali Shakkouf** — Post-Graduate student; ITMO University, Faculty of Control Systems and Robotics;  
E-mail: ashakkuf@itmo.ru

Received 05.06.2023; approved after reviewing 22.06.2023; accepted for publication 27.09.2023.

**СПИСОК ЛИТЕРАТУРЫ**

1. *Basha S. S., Dubey S. R., Pulabaigari V. and Mukherjee S.* Impact of fully connected layers on performance of convolutional neural networks for image classification // Neurocomputing. 2020. Vol. 378. P. 112—119.
2. *Zhou W., Wang H. and Wan Z.* Ore image classification based on improved CNN // Computers and Electrical Engineering. 2022. Vol. 99, art. N 107819.
3. *Gao X., Xing G., Roy S., and LiuH.* RAMP-CNN: A novel neural network for enhanced automotive radar object recognition // IEEE Sensors J. 2021. Vol. 21, N 4. P. 5119—5132.
4. *Ashiq F., Asif M., Ahmad M. B., Zafar S., Masood K., Mahmood T., Mahmood M. T. and LeeI. H.* CNN-based object recognition and tracking system to assist visually impaired people // IEEE Access. 2022. Vol. 10. P. 14819—14834.
5. *Abdelhamid A. A., El-Kenawy E.-S.-M., Alotaibi B., Amer G. M., Abdelkader M. Y., Ibrahim A. and Eid M. M.* Robust speech emotion recognition using CNN+LSTM based on stochastic fractal search optimization algorithm // IEEE Access. 2022. Vol. 10. P. 49265—49284.
6. *Kwon S.* MLT-DNet: Speech emotion recognition using 1D dilated CNN based on multi-learning trick approach // Expert Systems with Applications. 2021. Vol. 167, art. N 114177.
7. *Zhang N., Wei X., Chen H. and Liu W.* FPGA implementation for CNN-based optical remote sensing object detection // Electronics. 2021. Vol. 10, N 3. P. 282.
8. *Lopac N., Hrzic F., Vuksanovic I. P. and Lerga J.* Detection of non-stationary GW signals in high noise from Cohen's class of time-frequency representations using deep learning // IEEE Access. 2022. Vol. 10. P. 2408—2428.
9. *Horowitz M.* Computing's Energy Problem (and what we can do about it) // IEEE Intern. Solid State Circuits Conf. 2014. P. 10—14.
10. *Courbariaux M. and BengioY.* BinaryNet: Training deep neural networks with weights and activations constrained to +1 or -1 // ArXiv Journal. 2016. preprint arXiv: 1602.02830.
11. *Wang E., Davis J. J., Moro D., Zielinski P., Lim J. J., Coelho C., Chatterjee S., Cheung P. Y., Constantinides G. A.* Enabling binary neural network training on the edge // 5th Intern. Workshop on Embedded and Mobile Deep Learning. 2021. June. P. 37—38.
12. *Sohoni N. S., Berger C. R., Leszczynski M., Zhang J. and CRé.* Low-memory neural network training: A technical report // ArXiv journal. 2019. preprint arXiv:1904.10631.
13. *Courbariaux M., Bengio Y. and Jean-Pierre D.* Binaryconnect: Training deep neural networks with binary weights during propagations // ArXiv e-prints. 2015. abs/1511.00363.
14. *Hinton G.* Neural networks for machine learning // Coursera (video lectures). 2012.
15. *Bengio Yo.* Estimating or propagating gradients through stochastic neurons // Technical Report arXiv:1305.2982. Universite de Montreal. 2013.
16. *Darabi S., Belbahri M., Courbariaux M. and Nia V. P.* BNN+: Improved binary network training. 2019. <https://openreview.net/pdf?id=SJfHg2A5tQ>.
17. *Shen M., Han K., Xu C., Wang Y.* Searching for accurate binary neural architectures // IEEE/CVF Intern. Conf. on Computer Vision Workshops. 2019.
18. *Wang Z., Lu J., Tao C., Zhou J., Tian Q.* Learning channel-wise interactions for binary convolutional neural networks // IEEE/CVF Conf. on Computer Vision and Pattern Recognition. 2019. P. 568.
19. *Xiaofan Lin, Cong Zhao, and Wei Pan.* Towards accurate binary convolutional neural network // NIPS. 2017. P. 344—352.

20. *Zechun Liu, Baoyuan Wu, Wenhan Luo, Xin Yang, Wei Liu, and Kwang-Ting Cheng.* Bi-real net: Enhancing the performance of 1-bit cnns with improved representational capability and advanced training algorithm // arXiv preprint. 2018. arXiv:1808.00278.
21. *Shen M., Liu X., Gong R., Han K.* Balanced binary neural networks with gated residual // IEEE Intern. Conf. on Acoustics, Speech and Signal Processing (ICASSP) 2020. 4197.
22. *Jianhao Zhang, Yingwei Pan, Ting Yao, He Zhao and Tao Mei.* dabnn: A super fast inference framework for binary neural networks on arm devices // arXiv preprint. 2019 arXiv:1908.05858.
23. *Cai Z.; He X.; Sun J. and Vasconcelos N.* Deep learning with low precision by half-wave gaussian quantization // IEEE Conf. on Computer Vision and Pattern Recognition (CVPR). 2017.
24. *Ioffe S. and Szegedy C.* Batch normalization: Accelerating deep network training by reducing internal covariate shift // Proc. of the 32nd Intern. Conf. on Machine Learning, ICML. 2015. P. 448—456.
25. *Wang P., He X., Li G., Zhao T., Cheng J.* Sparsity-inducing binarized neural networks // AAAI Conf. on Artificial Intelligence. 2020. N 34. P. 12192.
26. *Yang J., Shen X., Xing J., Tian X., Li H., Deng B., Huang J. and Hua X.-s.* Quantization networks // IEEE Conf. on Computer Vision and Pattern Recognition (CVPR). 2019.
27. *Zhu S., Dong X. and Su H.* Binary ensemble neural network: More bits per network or more networks per bit? // IEEE Conf. on Computer Vision and Pattern Recognition (CVPR). 2019.
28. *Anderson A. G. and Berg C. P.* The High-Dimensional Geometry of Binary Neural Networks // ArXiv Journal. 2017. abs/1705.07199.
29. *Qin Haotong, Gong Ruihao, Liu Xianglong, Bai Xiao, Song Jingkuan, Sebe Nicu.* Binary Neural Networks: A Survey // Pattern Recognition. 2020. N 105. 107281. DOI: 10.1016/j.patcog.107281.
30. *Liang T., Glossner J., Wang L., Shi S. and Zhang X.* Pruning and quantization for deep neural network acceleration: A survey // Neurocomputing. 2021. Vol. 461. P. 370—403.
31. *Xu Sheng, Liu Chang, Zhang Baochang, Lu Jinhu, Guo Guodong, Doermann D.* BiRe-ID: Binary Neural Network for Efficient Person Re-ID // ACM Trans. on Multimedia Computing, Communications, and Applications. 2022. N 18. DOI: 10.1145/3473340.
32. *Zhang K., Yin M. and Wang Y.* Why Quantization Improves Generalization: NTK of Binary Weight Neural Networks // ArXiv Journal. 2022. abs/2206.05916.
33. *Darabi S., Belbahri M., Courbariaux M. and Nia V. P.* Regularized binary network training // ArXiv Journal. 2018, 1812.11800.
34. *Wang S., Zhang C., Su D., Wang L., Jiang H.* High-precision binary object detector based on a bsf-xnor convolutional layer // IEEE Access 9. 2021. P. 106169.
35. *Rastegari M., Ordonez V., Redmon J. and Farhadi A.* Xnor-net: Imagenet classification using binary convolutional neural networks // ECCV. 2016. P. 525—542.
36. *Barry D., Shah M., Keijser M., Khan H. and Hopman B.* XYolo: A model for real-time object detection in humanoid soccer on low-end hardware // ArXiv Journal: 1910.03159. 2019.
37. *Chen Hanlin, Zhuo Li'an, Zhang Baochang, Zheng Xiaowu, Liu Jianzhuang, Ji Rongrong, Doermann D., Guo Guodong.* Binarized Neural Architecture Search for Efficient Object Recognition // ArXiv Journal. 2020.
38. *Kung Jaeha, Zhang David, van der Wal G. Chai, Sek Mukhopadhyay S.* Efficient Object Detection Using Embedded Binarized Neural Networks // Journal of Signal Processing Systems. 2018. N 90. P. 1—14. DOI: 10.1007/s11265-017-1255-5.
39. *Wang Xingang, Siyang Sun, Yin Yingjie, Xu De, Wu Wengqi, Gu Qingyi.* Fast Object Detection Based on Binary Deep Convolution Neural Networks // CAAI Trans. on Intelligence Technology. 2018. N 3. DOI: 10.1049/trit.1026.
40. *Kim H., Choi K.* The implementation of a power efficient BCNN based object detection acceleration on a Xilinx FPGA-SoC // Intern. Conf. Internet Things (iThings) IEEE Green Comput. Commun. (GreenCom) IEEE Cyber, Phys. Social Comput. (CPSCom) IEEE Smart Data (SmartData). 2019. P. 240—243.
41. *Peng H., Chen S.* BDNN: Binary convolution neural networks for fast object detection // Pattern Recognition Lett. 2019. Vol. 125. P. 91—97.

42. Ojeda F. C., Bisulco A., Kepple D., Isler V. and Lee D. D. On-device event filtering with binary neural networks for pedestrian detection using neuromorphic vision sensors // IEEE Intern. Conf. Image Process. (ICIP) 2020. P. 3084—3088.
43. Wang Z., Wu Z., Lu J. and Zhou J. BiDet: An efficient binarized object detector // IEEE/CVF Conf. Comput. Vis. Pattern Recognition. 2020. P. 2049—2058.
44. Xu S., Zhao J., Lu J., Zhang B., Han S. and Doermann D. Layer-wise searching for 1-bit detectors // IEEE/CVF Conf. Comput. Vis. Pattern Recognition. (CVPR). 2021. P. 5682—5691.
45. Zhao J., Xu S., Wang R., Zhang B., Guo G., Doermann D. and Sun D. Data-adaptive binary neural networks for efficient object detection and recognition // Pattern Recognition. Lett. 2022. Vol. 153. P. 239—245.
46. Mani V. R. S., Saravanaselvan A. and Arumugam N. Performance comparison of CNN, QNN and BNN deep neural networks for real-time object detection using Zynq FPGA node // Microelectron. 2022. Vol. 119, art. N 105319.
47. Pérez-Hernández F., Tabik S., Lamas A., Olmos R., Fujita H., Herrera F. Object detection binary classifiers methodology based on deep learning to identify small objects handled similarly: application in video surveillance // Knowl. Base Syst. 2020. N 194 P. 105590.
48. Frickenstein A., Vemparala M.-R., Mayr J., Nagaraja N.-S., Unger C., Tombari F. and Stechele W. Binary DAD-Net: Binarized driveable area detection network for autonomous driving // IEEE Intern. Conf. Robot. Autom. (ICRA). 2020. P. 2295—2301.
49. Ajay B. S., MRao. Binary neural network based real time emotion detection on an edge computing device to detect passenger anomaly // 34th Intern. Conf. VLSI Design, 20th Intern. Conf. Embedded Syst. (VLSID). 2021. P. 175—180.
50. Zhuang B., Shen C., Tan M., Liu L. and Reid I. Structured binary neural networks for accurate image classification and semantic segmentation // IEEE/CVF Conf. on Computer Vision and Pattern Recognition (CVPR). 2019. P. 413—422.

**Сведения об авторе**

**Али Шаккуф** — аспирант; Университет ИТМО, факультет систем управления и робототехники;  
E-mail: ashakkuf@itmo.ru

Поступила в редакцию 05.06.2023; одобрена после рецензирования 22.06.2023; принята к публикации 27.09.2023.

---

# КОМПЬЮТЕРНОЕ МОДЕЛИРОВАНИЕ И АВТОМАТИЗАЦИЯ ПРОЕКТИРОВАНИЯ

## COMPUTER SIMULATION AND DESIGN AUTOMATION

---

УДК 535.8

DOI: 10.17586/0021-3454-2023-66-11-936-949

### МЕТОДИКА ЭФФЕКТИВНОГО КОМПЬЮТЕРНОГО МОДЕЛИРОВАНИЯ УСТРОЙСТВА ИЗМЕРЕНИЯ СВЕТОРАССЕИВАЮЩИХ СВОЙСТВ

В. Г. Соколов<sup>\*</sup>, И. С. Потемин, Д. Д. Жданов

Университет ИТМО, Санкт-Петербург, Россия

<sup>\*</sup>sokolovv1969@gmail.com

**Аннотация.** Рассматривается проблема компьютерного моделирования оптической системы со светорассеивающими элементами. Корректное моделирование устройств с такими элементами требует выполнения длительных световых расчетов с использованием стохастических трассировщиков лучей. Представлен подход к эффективному моделированию подобных установок на примере запатентованного устройства, предназначенно-го для измерения двунаправленной функции рассеяния, которая используется для описания светорассеивающих свойств. Предложена реалистичная компьютерная модель устройства, позволяющая произвести расчет допусков на отклонения в позиционировании наиболее критически важных блоков устройства и произведена оценка точности измерений с учетом допусков. Результаты моделирования измерений двунаправленных функций представле-ны в форме графиков и синтезированных изображений.

**Ключевые слова:** компьютерное моделирование, двунаправленная функция рассеяния, двунаправленная функция отражения, двунаправленная функция пропускания

**Благодарности:** работа выполнена при поддержке Российского научного фонда, грант № 22-11-00145.

**Ссылка для цитирования:** Соколов В. Г., Потемин И. С., Жданов Д. Д. Методика эффективного компьютерно-го моделирования устройства измерения светорассеивающих свойств // Изв. вузов. Приборостроение. 2023. Т. 66, № 11. С. 936—949. DOI: 10.17586/0021-3454-2023-66-11-936-949.

### METHODOLOGY FOR EFFECTIVE COMPUTER MODELING OF A DEVICE FOR MEASURING LIGHT SCATTERING PROPERTIES

V. G. Sokolov<sup>\*</sup>, I. S. Potemin, D. D. Zhdanov

ITMO University, St. Petersburg, Russia

<sup>\*</sup>sokolovv1969@gmail.com

**Abstract.** The problem of computer simulation of an optical system with light scattering elements is considered. Correctly modeling devices with such elements requires lengthy light calculations using stochastic ray tracers. An approach to efficient modeling of such installations is presented using the example of a patented device designed to measure the bidirectional scattering function, which is used to describe light scattering properties. A realistic computer model of such a device is proposed, which makes it possible to calculate tolerances for deviations in the positioning of the most critical device blocks, and an assessment of the accuracy of its measurements is carried out. Results of measurement simulations of bidirectional functions are presented in the form of graphs and synthesized images.

**Keywords:** computer simulation, bidirectional scattering distribution function, bidirectional reflectance distribution function, bidirectional transmittance distribution function

**Acknowledgments:** this work was supported by the Russian Science Foundation, grant No. 22-11-00145.

**For citation:** Sokolov V. G., Potemin I. S., Zhdanov D. D. Methodology for effective computer modeling of a device for measuring light scattering properties. *Journal of Instrument Engineering*. 2023. Vol. 66, N 11. P. 936—949 (in Russian). DOI: 10.17586/0021-3454-2023-66-11-936-949.

**Введение.** Двунаправленная функция рассеяния (ДФР) является одним из основных способов задания оптических свойств светорассеивающих объектов, таких как поверхности с микротекстурами, диффузные пленки, покрытия с объемными микроструктурами (краски, чернила) и др. [1—4]. Способ ее получения — оптические измерения. На современном рынке представлено множество различных установок для измерения ДФР [5—11]. Кроме того, в настоящее время активно ведется их разработка, что обуславливает важность виртуального прототипирования подобных измерительных устройств, необходимого для определения параметров их компонентов, расчета допусков и оценки точности измерений, которая может быть достигнута для проектируемой схемы. Двунаправленная функция рассеяния описывает угловое распределение света, рассеянного образцом, в зависимости от направления наблюдения и в общем случае должна быть определена во всем угловом пространстве освещения и наблюдения с учетом спектрального преобразования светового излучения. Иными словами, ДФР является многомерной функцией, требующей длительных расчетов для ее полного определения. Рассеивающие образцы могут иметь различные свойства, от близких к диффузным до зеркальных, и в случае последних требуется очень высокое угловое разрешение фотоприемного блока установки для измерений ДФР. Такие модели имеют низкую эффективность, так как приемниками устройства регистрируется лишь малая часть рассеянного светового потока по отношению к общему световому потоку, излучаемому источником света устройства. С другой стороны, оценка допусков на отклонения элементов устройства требует многочисленных расчетов при определении взаимного влияния множества параметров различных блоков устройства. Следует учитывать также, что для оптических расчетов систем с рассеивающими элементами применяются довольно медленные методы стохастической трассировки лучей. Все перечисленные проблемы крайне усложняют эффективное виртуальное прототипирование подобных устройств. В настоящей статье представлен подход к эффективному моделированию подобных установок на примере оптической схемы запатентованного высокоточного устройства для измерения ДФР [12].

**Измерительная установка.** Установка, оптическая схема которой представлена на рис. 1, содержит следующие основные элементы: блок образца 1, осветительный блок 2, коррекционный блок 3, блок поворотных зеркал 4 и приемный блок 5.




Рис. 1

Блок образца 1 используется для точного позиционирования измеряемого образца в пространстве, а также обеспечивает модификацию азимутального направления освещения образца с помощью вращения вокруг вертикальной оси. Основная функция светильного блока 2 — освещение измеряемого образца монохромным пучком, близким к параллельному. Белый свет, излучаемый источником света, проецируется с помощью рефлектора сферической формы и входного линзового конденсора на входную щель монохроматора. Свет, излучаемый выходной щелью монохроматора в узком спектральном интервале, проходя через блок поворотных зеркал, проецируется на образец. Блок поворотных зеркал 4, вращающийся вокруг оптической оси светильного блока, позволяет изменять полярный угол направления освещения образца. Приемный блок 5, предназначенный для детектирования рассеянного света, состоит из набора фотоприемных узлов, размещенных на дуге в четверть окружности, которые и детектируют рассеянный свет. Для обеспечения детектирования рассеянного света в угловом пространстве дуга с фотоприемными узлами имеет возможность азимутального вращения вокруг вертикальной оси. Для повышения углового разрешения измерений дуга с фотоприемными узлами может вращаться (качаться) в полярном направлении в пределах углового шага между соседними фотоприемными узлами.

Оптическая схема прибора предусматривает дополнительный контроль флуктуаций светового потока, излученного источником света, с помощью коррекционного блока 3. Для обеспечения этой функциональности часть света, излучаемого светильным блоком, перенаправляется с помощью светофильтра 6 в коррекционный блок. Отметим, что при моделировании коррекционный блок не рассматривается вообще, так как для компьютерной модели не существует проблем флюктуаций излучения светового потока источником света. Блок фотоприемного узла, оборудованный фокусирующей линзой, диафрагмой с переменным диаметром и фотодиодом, позволяет детектировать свет с высоким угловым разрешением в пределах от 0,5 до 2,5°.

Для лучшего понимания работы устройства далее рассмотрена динамика функционирования его отдельных блоков (рис. 2).




Рис. 2

На рис. 2, *a* показана оптическая схема устройства в статике с некоторым исходным положением всех подвижных узлов и трассировкой лучей. Полярное вращение дуги фотоприемника (рис. 2, *б*) запускается для измерений с высоким угловым разрешением, когда

свойства образцов близки к зеркальным. На следующем шаге (рис. 2, в) осуществляется азимутальный поворот фотоприемников вокруг вертикальной оси для охвата измерениями всего углового пространства. При измерениях образца с изотропным рассеянием диапазон изменения угла  $\beta$  составляет  $0\ldots180^\circ$ , а при измерениях анизотропных образцов диапазон расширяется до  $360^\circ$ . Следующие два поворота предназначены для изменения направления освещения. На рис. 2, г показан поворот блока образца вокруг вертикальной оси на угол  $\gamma$ , диапазон этого поворота, необходимого только при измерении анизотропных образцов, составляет  $0\ldots360^\circ$ . Вращение зеркального блока, задающее полярный угол освещения  $\sigma$ , представлено на рис. 2, д. При измерении двунаправленной функции отражения (ДФО) угол  $\sigma$  изменяется в диапазоне  $0\ldots90^\circ$ , а при измерении двунаправленной функции пропускания (ДФП) — в диапазоне  $90\ldots180^\circ$ . Завершающий этап схемы измерения — изменение длины волны монохроматором (рис. 2, е), длина волны изменяется в видимом диапазоне от 380 до 710 нм.

Для вычисления ДФР согласно приведенной схеме измерений во всем угловом пространстве освещения и наблюдения и широком диапазоне длин волн видимой части спектра необходимо выполнить, как было указано, огромное количество вычислений. Все связанные с этим проблемы были учтены в процессе построения компьютерной модели, представленной далее.

**Оптическая схема компьютерной модели.** Для оптического моделирования устройств со светорассеивающими элементами используются достаточно сложные и малоэффективные алгоритмы стохастической трассировки лучей. Некоторые проблемы, связанные с моделированием подобных устройств, изучались на компьютерных моделях реальных измерительных систем: например, в [13, 14] содержатся рекомендации по выбору оптимальных трассировщиков лучей и введению обоснованных упрощений, которые могут быть использованы при разработке компьютерной модели без внесения значительных погрешностей, влияющих на точность и достоверность результатов моделирования. Эти рекомендации были использованы при разработке компьютерной модели измерительной установки. Принципиальная оптическая схема установки для измерений ДФР представлена на рис. 3 (все размеры на рисунке приведены в миллиметрах). Компьютерная модель включает все основные блоки устройства, а именно блок образца, осветительный и приемный блоки, блок поворотных зеркал.




Рис. 3

Блок образца представлен в упрощенном виде несколькими элементами: однослойной плоской поверхностью с двумя прямоугольными рамками, расположенными над и под образцом с квадратными отверстиями. Плоскость используется в качестве образца, рассеивающие свойства которого и необходимо промоделировать с помощью компьютерной модели, а прямоугольные рамки моделируют элементы фиксации образца. Образец в модели можно повернуть вокруг вертикальной оси на угол  $\alpha$  для изменения азимута направления освещения, что необходимо при измерении анизотропных образцов.

Блок поворотных зеркал моделируется простым набором трех квадратных плоских поверхностей с зеркальными свойствами (зеркала 1, 2, 3 на рис. 3). Зеркала поворотного блока неподвижны относительно друг друга, но сам блок может поворачиваться на угол  $\sigma$  вокруг оси, образованной нижней стороной квадрата, содержащего образец и зеркало 1, и совпадающей с оптической осью светильного блока. Этот поворот обеспечивает плавное линейное изменение полярного угла падения света на образец. Коэффициент отражения зеркал был установлен равным 95 %, что соответствует стандартным отражающим покрытиям, применяемым в оптическом приборостроении.

Осветительный блок представлен источником света, рефлектором сферической формы, входным конденсором, монохроматором и выходным конденсором. В качестве источника света выбрана модель ксеноновой лампы [15]. Модель лампы представлена с помощью стеклянной колбы, патронов и основного объекта (эффективного размера дуги) — самосветящегося цилиндрического тела радиусом 0,5 мм и длиной 2,2 мм. Спектrogramма излучения и световой поток заданы в соответствии со спецификацией, предоставленной производителем реальной лампы. Ламповый рефлектор имеет сферическую форму с центром кривизны, помещенным в центр светящейся дуги лампы. Рабочая поверхность рефлектора имеет коэффициент зеркального отражения, равный 95 %. Для ускорения расчета все линзы в модели представлены идеальными линзами. Моделируемое устройство не относится к классу изображающей оптики, поэтому не нуждается в точном воспроизведении реального изображения.

В качестве монохроматора в устройстве используется готовое изделие — минимонохроматор с дифракционной решеткой [16]. Реальное моделирование такого прибора с учетом волновых эффектов является экстремально сложной задачей, поэтому здесь также используется упрощенная модель с непрозрачной диафрагмой прямоугольной формы, размер которой совпадает с входной/выходной щелью реального монохроматора. Прямоугольная щель моделируется прозрачной поверхностью, спектральный интервал пропускания которой может варьироваться произвольно. Для ускорения расчета этот интервал в моделировании совпадает со всем видимым диапазоном, равным 380...710 нм, т.е. все длины волн рассчитываются одновременно, так как используемый трассировщик лучей имеет такую возможность.

Модель приемного блока была разработана в двух вариантах: более близком к „реальному“ и упрощенном. В „реальном“ варианте блоки фотоприемников (рис. 4, а) состоят из идеальных фокусирующих линз 1, оправы 2, диафрагмы 3 с переменным диаметром и детектора светового потока 4. Детекторы расположены по дуге окружности, как и в реальной схеме устройства, их количество задается сеткой полярных углов, имеется дополнительная возможность их полярного вращения и азимутального вращения вокруг вертикальной оси.




Рис. 4

Однако моделирование измерений ДФР во всем угловом пространстве на основе такой „реальной“ модели приемного блока с последовательными азимутальными поворотами и полярными сдвигами в случае использования высокого разрешения крайне малоэффективно. Вследствие этого „реальная“ модель приемного блока использовалась только для тестирования. Для моделирования ДФР, определенной на полной и детальной угловой сетке, был создан второй упрощенный вариант модели приемного блока (рис. 4, б). В этом варианте приемный блок представлен набором виртуальных детекторов круглой формы диаметром 5 мм и переменным угловым разрешением в пределах 0,5...2,5°, соответствующим входной спецификации моделируемого устройства. Детекторы не влияют на распространение света в системе и могут быть установлены в любом количестве с произвольным угловым шагом как в азимутальном, так и в полярном направлении, их пересечение также не влияет на распространение рассеянного света; таким образом, все направления наблюдения, используемые при измерениях, можно вычислить одновременно. Такой подход возможен только при использовании прямых трассировщиков лучей, не зависящих от наблюдателя (камеры) [18].

**Методика вычисления ДФР в компьютерной модели.** При известных яркостях измеряемого образца и эталона (образца с известной ДФР) для заданных направлений освещения, наблюдения и длины волны [18] ДФР может быть определена в соответствии с формулой

$$K(\mathbf{i}, \mathbf{o}, \lambda) = \frac{L_{\text{sample}}(\mathbf{i}, \mathbf{o}, \lambda)}{L_{\text{etalon}}(\mathbf{i}, \mathbf{o}, \lambda)} K_{\text{etalon}}(\mathbf{i}, \mathbf{o}, \lambda), \quad (1)$$

где  $K(\mathbf{i}, \mathbf{o}, \lambda)$  — коэффициент яркости для данных направлений освещения и наблюдения, определяемых векторами  $\mathbf{i}$  и  $\mathbf{o}$  соответственно, и данной длины волны  $\lambda$ , а угловое и спектральное распределение коэффициента яркости и будет определять ДФР;  $L_{\text{sample}}(\mathbf{i}, \mathbf{o}, \lambda)$ ,  $L_{\text{etalon}}(\mathbf{i}, \mathbf{o}, \lambda)$  — яркости (или световые потоки) образца и эталона, измеренные при одинаковых условиях наблюдения и освещения;  $K_{\text{etalon}}$  — известный коэффициент яркости эталона.

Как правило, в качестве эталона используется образец с рассеивающими свойствами, близкими к идеальным равномерным по всем направлениям наблюдения, ДФР которого известна. При компьютерном моделировании можно использовать просто идеальные ламбертовские свойства с единичным коэффициентом яркости для всех длин волн и направлений наблюдения и освещения.

Для ускорения процесса вычислений ДФР при компьютерном моделировании важно выбрать оптимальный метод светового расчета. Следует отметить, что в настоящее время существует достаточно много эффективных методов, разработанных для расчета светорассеяния,

однако в большинстве из них используются гибридные формы прямой (от источника света) и обратной (от наблюдателя, камеры) трассировки лучей. Методы обратной трассировки не позволяют производить вычисления для нескольких направлений наблюдения одновременно. Вследствие этого был выбран достаточно простой и известный метод прямой стохастической трассировки лучей Монте-Карло, который позволяет рассчитывать неограниченное число виртуальных детекторов (см. рис. 4, б) и доступен в программном комплексе Lumicept [19], используемом для моделирования в данной работе.

Еще одной задачей при расчете ДФР является приведение системы координат, в которой определена эта функция, к требуемому типу. В компьютерной модели положение детектора определяется в обычной геоцентрической системе координат, где направление наблюдения задается двумя углами: азимутальным  $\alpha$  и полярным  $\beta$ . Однако при использовании Lumicept [20] ДФР вычисляется в более сложной системе координат, как показано на рис. 5, где ДФР определяется относительно зеркально отраженного луча в случае ДФО и преломленного луча в случае ДФП, направление наблюдения задается углами  $\theta$  и  $\varphi$ . Угол  $\theta$  — это угол между направлением зеркального отражения  $\mathbf{r}$  и направлением наблюдения  $\mathbf{o}$ , а угол  $\varphi$  определяет поворот направления наблюдения вокруг направления зеркального отражения. Таким образом, данные, рассчитанные в исходной геоцентрической системе координат компьютерной модели (углы  $\alpha, \beta$ ), должны быть преобразованы в  $\sigma, \theta, \varphi$ .




Рис. 5

По рис. 5 можно определить углы  $\alpha, \beta$  при известных  $(o_x, o_y, o_z)$  ортах вектора наблюдения  $\mathbf{o}$  по следующей формуле:

$$\alpha = \operatorname{arctg} 2(o_x/o_y); \quad \beta = \arccos \left( \frac{\sqrt{o_x^2 + o_y^2}}{|\mathbf{o}|} \right). \quad (2)$$

Орты вектора  $\mathbf{o}$  легко вывести для случая нормального освещения образца под углом  $\sigma = 0^\circ$ :

$$o'_x = \cos \theta; \quad o'_y = \sin \theta \sin \varphi; \quad o'_z = \sin \theta \cos \varphi. \quad (3)$$

Выполнив поворот на требуемый угол  $\sigma$ , можно получить значения ортов вектора наблюдения  $\mathbf{o}$  для общего случая с ненулевым  $\sigma$ :

$$\begin{bmatrix} o_x \\ o_y \\ o_z \end{bmatrix} = \begin{bmatrix} \cos \sigma & 0 & -\sin \sigma \\ 0 & 1 & 0 \\ \sin \sigma & 0 & \cos \sigma \end{bmatrix} \cdot \begin{bmatrix} o'_x \\ o'_y \\ o'_z \end{bmatrix}. \quad (4)$$

По формулам (2) и (4) можно определить углы  $\alpha$  и  $\beta$  как функции от  $\sigma$ ,  $\theta$  и  $\varphi$  и привести расчетную ДФР к требуемой угловой сетке. Общий алгоритм расчета ДФР в компьютерной модели представлен на рис. 6.




Рис. 6

Для расчета ДФР на поверхности образца задаются исследуемые свойства рассеяния. Кроме того, задаются сетка углов падения света  $\sigma$  для определения условий освещения образца, сетка углов  $\alpha, \beta$ , определяющая полный набор положений виртуальных детекторов, и сетка выходных углов  $\varphi, \theta$ . Сначала задаются свойства диффузного эталона (ДФР) с единичным коэффициентом яркости. Положение зеркального блока задается по начальному углу  $\sigma$ , а положение детекторов — по сеткам углов  $\alpha$  и  $\beta$ . Затем выполняется расчет световых потоков, создаваемых рассеянным светом на детекторах, с помощью трассировки лучей методом Монте-Карло. Расчеты повторяются для всех углов  $\sigma$  с соответствующим поворотом зеркального узла.

После выполнения всех расчетов для эталона та же процедура повторяется для рассеивающих свойств исследуемого образца. Далее эти световые потоки пересчитываются в распределение коэффициента яркости по формуле (1) с последующим преобразованием к сетке углов  $\sigma, \phi, \theta$  с помощью формул (2)–(4) и сохранением в файл с ДФР.

**Оптимизация компьютерной модели для расчета допусков.** Устройство, предназначенное для измерения ДФР, содержит много подвижных элементов, отклонение параметров которых может существенно влиять на точность измерений. Оценка допусков в таком устройстве предполагает выполнение многочисленных расчетов. Для решения проблемы ускорения вычислений использована декомпозиция модели, основная идея которой — разделение модели на две части: осветительный блок и остальные элементы. Основными выходными характеристиками осветительного блока (рис. 7) являются значение освещенности и равномерность освещения, создаваемого на поверхности образца, и угловая расходимость пучка освещения. Угловая расходимость пучка определяется в большей степени расстоянием между выходным зрачком осветительного блока и поверхностью образца, повлиять на это расстояние без кардинального изменения схемы прибора практически невозможно.

Угловые и пространственные отклонения осветительного блока представлены на рис. 8.




Рис. 7




Рис. 8

Подобные отклонения в позиционировании можно выделить и для отдельных элементов осветительного блока: конденсоров, лампы, лампового рефлектора, все эти отклонения использовались при оценке допусков. Допуски для элементов осветительного блока рассчитывались исходя из условия, что световой поток, падающий на образец, расположен в его центре и имеет размеры не менее  $5 \times 5$  мм, не отличающиеся более чем на 5–10 % от значе-

ния, рассчитанного для нулевых отклонений. Расчет допусков выполнялся по стандартному алгоритму. Допустимые угловые и пространственные отклонения (только минимальные значения) представлены в табл. 1. В основном эти отклонения относятся к позиционированию лампового рефлектора, всего осветительного блока и выходного конденсатора. Допуски для других элементов более грубые.

Таблица 1

Устройство	Угловые отклонения, ...°	Пространственные отклонения, мм
Осветительный блок	±0,05	±0,025
Остальные элементы	±0,05	±0,1

В дальнейших расчетах для ускорения вычислений при моделировании всего устройства осветительный блок подсветки был заменен на лучевой источник света („Rayset“ в терминологии Lumicept [20]). Этот источник воспроизводит полностью угловое и пространственное распределение света, излучаемое осветительным блоком, и представляет собой набор лучей, записанных на выходе осветительного блока (выходном конденсоре). Запись лучей производится при наихудшем сочетании отклонений элементов осветительного блока. При использовании лучевого источника света трассировка лучей стартует от выходного конденсора, а не от источника света, что многократно ускоряет процесс вычислений при сохранении корректности моделирования устройства в целом. Для примера, вычисление одной ДФР в исходной модели с „реальной“ моделью фотоприемников (см. рис. 4, a) и полной трассировкой лучей от источника света (без замены осветительного блока на лучевой источник света) занимает на достаточно мощном компьютере с процессором „AMD EPYC 7281 16-Core Processor, 2100 Mhz, 16 Core(s), 16 Logical Processor(s)“ около недели, а в финальной компьютерной модели, представленной на рис. 9, — около 1 мин.




Рис. 9

Аналогично угловым и пространственным отклонениям осветительного блока (см. рис. 8) подобные отклонения были выделены в позиционировании других элементов устройства: образца, поворотного блока зеркал, дуги с фотоприемными узлами приемного блока и отдельно фотоприемных узлов. При расчете допусков вместо освещенности образца использовалось отклонение между теоретической и моделированной ДФР. В качестве теоретической ДФР было выбрано гауссовское распределение с угловой шириной  $2^\circ$  (эта функция рассматривается далее), а отклонение между теоретической и моделируемой ДФР вычислялось как относительное среднеквадратическое отклонение, определяемое формулой

$$\text{RMSE} = \sqrt{\frac{\sum_i \left( \frac{L_{si} - L_{ti}}{0,5(L_{si} + L_{ti})} \right)^2}{n}} \cdot 100\%, \quad (5)$$

где  $L_{si}$  — значение ДФР (коэффициента яркости), вычисленное с помощью компьютерной модели;  $L_{ti}$  — значение теоретической ДФР, индекс „ $i$ “ определяет направление наблюдения и освещения;  $n$  — общее количество значений коэффициента яркости в ДФР для всех комбинаций направлений наблюдения и освещения; при расчете ДФР использовался 5%-ный порог, который не должен превышать RMSE.

Допуски на угловые и пространственные сдвиги элементов блока образца, блока поворотных зеркал, дуги с фотоприемниками также представлены в табл. 1. Как и в случае с осветительным блоком, здесь представлены только наиболее жесткие отклонения, критичные для некоторых элементов устройства типа зеркал поворотного блока. Оценка точности устройства производилась с учетом допусков — при худшей комбинации отклонений параметров устройства в целом.

**Результаты моделирования.** Для оценки точности устройства с помощью разработанной компьютерной модели, как и в случае оценки допусков, было выбрано распределение Гаусса:

$$I(\theta) = I_o \exp \left( -\left( \frac{\theta}{\zeta} \right)^2 \right),$$

где  $\zeta$  — угловая ширина (угол, при котором сила света  $I$  уменьшается вдвое по отношению к силе света  $I_o$  в зеркальном направлении).

Для исследования были выбраны два варианта гауссовой ДФО с угловой шириной 2 и 15°. Первый вариант функции соответствует зеркальным рассеивающим свойствам, второй вариант представляет более диффузные свойства. Результаты моделирования приведены на рис. 10:  $a, b$  — сравнительные графики ДФО, полученных в результате моделирования, и их теоретических аналогов.




Рис. 10

Все расчеты проводились для минимального углового поля зрения фотоприемного узла, равного  $0,5^\circ$ . На графиках показано распределение коэффициента яркости, приведенное для трех углов освещения  $\sigma = 0, 30, 60^\circ$  в плоскости падения света (их максимумы смещены вдоль оси абсцисс). На рис. 10, в, г представлены изображения, предназначенные для визуального сравнения, — они синтезированы для сферы со свойствами ДФР (теоретическими и смоделированными), помещенной в куб с шахматными гранями и освещенной прямоугольным источником света. Численные результаты сравнения в форме среднеквадратического отклонения, вычисленного по формуле (5), представлены в табл. 2.

Таблица 2

Угол освещения $\sigma, \dots^\circ$	RMSE, %, при	
	$\zeta = 2^\circ$	$\zeta = 15^\circ$
0	4,79	0,37
30	4,21	0,56
60	3,85	0,74

Как показывает анализ рис. 10, графики смоделированных ДФО практически совпадают с теоретическими, те же выводы можно сделать по визуальному сравнению синтезированных изображений.

Отклонение между смоделированной и теоретической ДФР не превышает порог в 5 % даже для сложной узконаправленной ДФО.

**Заключение.** Устройства измерений двунаправленных функций рассеяния чрезвычайно не эффективны с точки зрения светового моделирования вследствие малых угловых и пространственных апертур приемников света. Представленные в статье методы компьютерного моделирования, такие как одновременный расчет множества детекторов света, прямая трасировка лучей методом Монте-Карло, декомпозиция модели с отдельным расчетом осветительного блока и его последующей заменой лучевым источником света, позволяют существенно (более чем в 100 раз) ускорить оптические вычисления, необходимые для расчета допусков и анализа точности исследуемого устройства.

## СПИСОК ЛИТЕРАТУРЫ

1. Bartell F. O., Dereniak E. L., Wolfe W. L., The Theory and Measurement of Bidirectional Reflectance Distribution Function (BRDF) And Bidirectional Transmittance Distribution Function (BTDF) // Proc. SPIE 0257, Radiation Scattering in Optical Systems, 3 March 1981. DOI: org/10.1117/12.959611.
2. Torrance K., Sparrow E. Theory for Off-Specular Reflection from Roughened Surfaces // J. Optical Soc. Amer. 1976. Vol. 57. P. 1105—1114.
3. Ward J. G. Measuring and modeling anisotropic reflection // Proc. of SIGGRAPH. 1992. P. 265—272. DOI: 10.1145/133994.134078.
4. Blinn J. F. Models of light reflection for computer synthesized pictures // Proc. 4th Annual Conf.on Computer Graphics and Interactive Techniques. 1977. P. 192. DOI: 10.1145/563858.563893.
5. X-Rite MA98 Portable Multi-Angle Spectrophotometers, X-Rite [Электронный ресурс]: <[https://www.tricolor.pl/images/pdf/L10-372\\_MA98\\_en.pdf](https://www.tricolor.pl/images/pdf/L10-372_MA98_en.pdf)>, 7.11.2023.
6. MA-T12 Handheld Multi-Angle Spectrophotometer | X-Rite 12-Angle Color Measurement, X-Rite [Электронный ресурс]: <<https://www.xrite.com/categories/portable-spectrophotometers/ma-family/ma-t12>>, 7.11.2023.
7. Optical Scattering Measurement & Equipment | Synopsys, Synopsys Mini-Diff VPro, SYNOPSIS, [Электронный ресурс]: <<https://www.synopsis.com/optical-solutions/scattering-measurements.html#MiniDiffVPRO>>, 7.11.2023.
8. Imaging Sphere for Scatter and Appearance Measurement IS-SA, Radiant Vision Systems, [Электронный ресурс]: <<https://sphereoptics.de/wp-content/uploads/2014/03/Radiant-ImagingSphere-IS-SA.pdf>>, 7.11.2023.
9. Ansys Optical Measurement Device Solutions, ANSYS AMO-PRO, AMO-Premium, Ansys [Электронный ресурс]: <<https://www.ansys.com/content/dam/product/optical/omd/ansys-omd-technical-description-sheet.pdf>>, 7.11.2023.

10. Gonio Photometer GP-700 | Murakami Color Research Laboratory [Электронный ресурс]: <[https://www.mcrl.co.jp/english/products/p\\_color\\_sp/detail/GP700.html](https://www.mcrl.co.jp/english/products/p_color_sp/detail/GP700.html)>.
11. Gonio-Spectrophotometric Color Measurement System GCMS-4B, [Электронный ресурс]: <[https://www.mcrl.co.jp/english/products/p\\_color\\_sp/detail/GCMS4B.html](https://www.mcrl.co.jp/english/products/p_color_sp/detail/GCMS4B.html)>, 7.11.2023.
12. Пат. RU 2790949 С1. Устройство для измерения двунаправленной функции рассеяния (варианты) / В. Г. Соколов, И. С. Потемин, Д. Д. Жданов. Опубл. 2023.02.28 [Электронный ресурс]: <<https://patents.google.com/patent/RU2790949C1/ru>>.
13. Sokolov V., Potemin I., Wang Y. Virtual prototyping of BSDF measurements for materials with complex scattering properties // Proc. of SPIE. 2021. Vol. 11876. P. 118760K.
14. Sokolov V., Potemin I., Zhdanov D. D., Barladian B. Simulation of the BSDF measurements for scattering materials with GP-200 gonio-photometer for light guiding plates // Proc. of SPIE. 2021. Vol. 11783. P. 1178305.
15. Xenon Arc Lamp, 150 W, Ozone Free, Newport [Электронный ресурс]: <<https://www.newport.com/p/6255>>, 7.11.2023.
16. Oriel mini monochromator, 2023 [Электронный ресурс]: <[https://research.engineering.ucdavis.edu/woodall/wp-content/uploads/sites/84/2016/02/oriel\\_78025\\_specs.pdf](https://research.engineering.ucdavis.edu/woodall/wp-content/uploads/sites/84/2016/02/oriel_78025_specs.pdf)>, 7.11.2023.
17. González O., Rodríguez S., Pérez-Jiménez R., Mendoza B., Ayala A. Comparison of Monte Carlo ray-tracing and photon-tracing methods for calculation of the impulse response on indoor wireless optical channels // Opt. Express. 2011. N 19. P. 1997-2005.
18. Nicodemus F. E. Directional Reflectance and Emissivity of an Opaque Surface // Appl. Opt. 1965. N 4. P. 767—775.
19. Lumicept — Hybrid Light Simulation Software, 2023 [Электронный ресурс]: <<https://integra.jp/en/products/lumicept>>, 7.11.2023.

#### *Сведения об авторах*

**Вадим Геннадьевич Соколов**

— Университет ИТМО, факультет программной инженерии и компьютерной техники; старший научный сотрудник; E-mail: sokolovv1969@gmail.com

**Игорь Станиславович Потемин**

— канд. техн. наук; Университет ИТМО, факультет программной инженерии и компьютерной техники; доцент; E-mail: ipotemin@yandex.ru

**Дмитрий Дмитриевич Жданов**

— канд. физ.-мат. наук; Университет ИТМО, факультет программной инженерии и компьютерной техники; доцент; E-mail: ddzhdanov@mail.ru

Поступила в редакцию 19.07.2023; одобрена после рецензирования 17.08.2023; принята к публикации 27.09.2023.

#### REFERENCES

1. Bartell F.O., Dereniak E.L., Wolfe W.L. *Radiation Scattering in Optical Systems*, Proc. SPIE, 3 March 1981, vol. 0257, <https://doi.org/10.1117/12.959611>.
2. Torrance K. and Sparrow E. J. *Optical Soc. America*, 1976, vol. 57, pp. 1105–1114.
3. Ward J.G. *Proc. of SIGGRAPH*, 1992, pp. 265–272, doi:10.1145/133994.134078.
4. Blinn J.F. *Proc. 4th Annual Conf. on Computer Graphics and Interactive Techniques*, 1977, pp. 192, DOI:10.1145/563858.563893.
5. X-Rite MA98 Portable Multi-Angle Spectrophotometers, [https://www.tri-color.pl/images/pdf/L10-372\\_MA98\\_en.pdf](https://www.tri-color.pl/images/pdf/L10-372_MA98_en.pdf).
6. MA-T12 Handheld Multi-Angle Spectrophotometer | X-Rite 12-Angle Color Measurement, <https://www.xrite.com/categories/portable-spectrophotometers/ma-family/ma-t12>.
7. Optical Scattering Measurement & Equipment | Synopsys, Synopsys Mini-Diff VPro, <https://www.synopsys.com/optical-solutions/scattering-measurements.html#MiniDiffVPRO>.
8. Imaging Sphere for Scatter and Appearance Measurement IS-SA, Radiant Vision Systems, <https://sphereoptics.de/wp-content/uploads/2014/03/Radiant-ImagingSphere-IS-SA.pdf>.
9. Ansys Optical Measurement Device Solutions, ANSYS AMO-PRO, AMO-Premium, Ansys, <https://www.ansys.com/content/dam/product/optical/omd/ansys-omd-technical-description-sheet.pdf>.
10. Gonio Photometer GP-700 / Murakami Color Research Laboratory, Murakami Color Research Laboratory, [https://www.mcrl.co.jp/english/products/p\\_color\\_sp/detail/GP700.html](https://www.mcrl.co.jp/english/products/p_color_sp/detail/GP700.html).
11. Gonio-Spectrophotometric Color Measurement System GCMS-4B, [https://www.mcrl.co.jp/english/products/p\\_color\\_sp/detail/GCMS4B.html](https://www.mcrl.co.jp/english/products/p_color_sp/detail/GCMS4B.html).

12. Patent RU2790949C1, *Ustroystvo dlya izmereniya dvunapravlennoy funktsii rasseyaniya (varianty)* (Device for Measuring the Bidirectional Scattering Function (Embodiments)), V.G. Sokolov, I.S. Potemin, D.D. Zhdanov, Priority 2022-07-26, Published 2023-02-28.
13. Sokolov V., Potemin I., Wang Y. *Proceedings of SPIE*, 2021, vol. 11876, pp. 118760K.
14. Sokolov V., Potemin I., Zhdanov D.D., Barladian B. *Proceedings of SPIE*, 2021, vol. 11783, pp. 1178305.
15. *Xenon Arc Lamp, 150 W, Ozone Free*, <https://www.newport.com/p/6255>.
16. *Oriel mini monochromator*, 2023, [https://research.engineering.ucdavis.edu/woodall/wp-content/uploads/sites/84/2016/02/oriel\\_78025\\_specs.pdf](https://research.engineering.ucdavis.edu/woodall/wp-content/uploads/sites/84/2016/02/oriel_78025_specs.pdf), 7.11.2023.
17. González O., Rodríguez S., Pérez-Jiménez R., Mendoza B., and Ayala A. *Opt. Express*, 2011, vol. 19, pp. 1997–2005.
18. Nicodemus F.E. *Appl. Opt.*, 1965, vol. 4, pp. 767–775.
19. *Lumicept – Hybrid Light Simulation Software*, <https://integra.jp/en/products/lumicept>.

**Data on authors****Vadim G. Sokolov**

— ITMO University, Faculty of Software Engineering and Computer Systems; Senior Researcher; E-mail: sokolovv1969@gmail.com

**Igor S. Potemin**

— PhD; ITMO University, Faculty of Software Engineering and Computer Systems; Associated Professor; E-mail: ipotemin@yandex.ru

**Dmitry D. Zhdanov**

— PhD; ITMO University, Faculty of Software Engineering and Computer Systems; Associated Professor; E-mail: ddzhdanov@mail.ru

Received 19.07.2023; approved after reviewing 17.08.2023; accepted for publication 27.09.2023.

---

# ВЫЧИСЛИТЕЛЬНЫЕ СИСТЕМЫ И ИХ ЭЛЕМЕНТЫ

## COMPUTING SYSTEMS AND THEIR ELEMENTS

---

УДК 004.272.45

DOI: 10.17586/0021-3454-2023-66-11-950-959

### АРИФМЕТИЧЕСКИЙ ВЫЧИСЛИТЕЛЬ НА ЭЛЕМЕНТАХ НЕЙРОННОЙ ЛОГИКИ

В. С. Титов, С. С. Шевелев\*

Юго-Западный государственный университет, Курск, Россия

\*schewelev@mail.ru

**Аннотация.** Представлен арифметический вычислитель, выполняющий операции сложения и вычитания чисел в формате с фиксированной запятой в прямом коде и построенный на элементах нейронной логики. Арифметические операции суммирования или вычитания выполняются при анализе кода операции и знаковых цифр чисел. Если сумма знаковых разрядов двоичных чисел и кода операции равна нулю, то выполняется операция суммирования, в противном случае — вычитание. При суммировании определяется перенос из младших разрядов в старшие, при вычитании вычисляется заем из старших разрядов в младшие. Предложенное устройство обладает повышенной скоростью вычислений, а использование нейроподобных элементов позволяет снизить аппаратную сложность.

**Ключевые слова:** вычислительный модуль, логическая схема, микропроцессор, нейронные логические элементы, система коммутации, суммирование, вычитание

**Ссылка для цитирования:** Титов В. С., Шевелев С. С. Арифметический вычислитель на элементах нейронной логики // Изв. вузов. Приборостроение. 2023. Т. 66, № 11. С. 950—959. DOI: 10.17586/0021-3454-2023-66-11-950-959.

### ARITHMETIC CALCULATOR BASED ON NEURAL LOGIC ELEMENTS

V. S. Titov, S. S. Shevelev\*

The Southwest State University, Kursk, Russia

\*schewelev@mail.ru

**Abstract.** An arithmetic calculator that performs addition and subtraction operations with numbers in a fixed-point format in direct code and is built on elements of neural logic, is presented. Arithmetic operations of summation or subtraction are performed by analyzing the operation code and signed digits of numbers. If the sum of the sign bits of binary numbers and the operation code is equal to zero, then the summation operation is performed, otherwise - subtraction. When summing, the transfer from low to high digits is determined; when subtracting, a loan from high to low digits is calculated. The proposed device has increased computing speed, and the use of neural-like elements allows reducing hardware complexity.

**Keywords:** computing modules, logic circuits, microprocessors, neural logic elements, switching system, summation, subtraction

**For citation:** Titov V. S., Shevelev S. S. Arithmetic calculator based on neural logic elements. *Journal of Instrument Engineering*. 2023. Vol. 66, N 11. P. 950—959 (in Russian). DOI: 10.17586/0021-3454-2023-66-11-950-959.

Многопроцессорные вычислительные системы с программируемой архитектурой могут быть созданы на базе логических интегральных схем FPGA высокой степени интеграции [1, 2]. Вычислительные комплексы обеспечивают параллелизм и распределение управляю-

ших процессоров, доступ к данным и их обработку, децентрализованное управление системой и асинхронное взаимодействие процессоров и модулей [3—5]. Специализированные вычислительные модули дополняются универсальными процессорами для ускоренного выполнения задач обработки символьной информации:  $P_1 \rightarrow (\cdot) Q_1$ ,  $P_2 \rightarrow (\cdot) Q_2$ , ...,  $P_n \rightarrow (\cdot) Q_n$ : применяя конечный упорядоченный набор формул подстановки вхождений к обрабатываемому слову, упорядочиваем данные  $a'_1 \leq a'_2 \leq \dots \leq a'_n$ , также выполняется распределение ресурсов между локализованными центрами  $X_h PC_q \# X_d PC_k \# X_m PC_t / Y_x CM_s \# Y_k CM_p \# Y_r CM_g$  [6].

Специализированные модули ориентированы на ускоренное выполнение конкретных функций, что позволяет значительно повысить эффективную производительность при решении только определенных задач. Микропроцессоры ориентированы на выполнение сложных последовательностей логических операций — инверсии, конъюнкции, дизъюнкции, исключающего ИЛИ, эквивалентности; математические микропроцессоры предназначены для повышения производительности при выполнении арифметических операций — суммирования, вычитания, произведения, деления с фиксированной запятой и в формате с плавающей запятой. Эти специальные схемы способны обеспечить высокую производительность [7, 8].

В настоящей статье представлен разработанный арифметический вычислитель, выполняющий основные математические операции и построенный на элементах нейронной логики [9].

Нейроподобные структуры работают с высокой надежностью, что не приводит к избыточным затратам на оборудование. Сумма одноразрядных двоичных чисел и перенос в старший разряд, а также разность и заем из старшего разряда при вычитании определяются на элементах функциональной схемы [10, 11]. Арифметические операции выполняются в прямых кодах  $S_{\text{пр.к}} = A_{\text{пр.к}} + B_{\text{пр.к}}$ ,  $R_{\text{пр.к}} = A_{\text{пр.к}} - B_{\text{пр.к}}$ . Вычитание чисел выполняется в два цикла работы устройства, сложение — в один цикл. Выход из строя большого количества элементов нейронной сети не приводит к сбоям в работе всей структуры [12—14].

Полный одноразрядный сумматор предназначен для сложения трех одноразрядных двоичных чисел. Устройство имеет три входа — двоичные разряды  $A_i$ ,  $B_i$  и результат переноса  $P_{i+1}$  предыдущего сумматора, и два выхода — результат сложения  $S_i$  и сигнал переноса  $P_i$  в старший разряд. Сумма  $S_i$  чисел определяется по формуле

$$S_i = \bar{P}_{i+1} \bar{A}_i B_i V \bar{P}_{i+1} A_i \bar{B}_i V P_{i+1} \bar{A}_i \bar{B}_i V P_{i+1} A_i B_i = P_{i+1} \oplus A_i \oplus B_i.$$

Перенос  $P_i$  из младшего разряда в старший при сложении чисел определяется как

$$P_i = A_i B_i V P_{i+1} A_i V P_{i+1} B_i.$$

Полный одноразрядный вычитатель вычисляет разность двоичных чисел; входные данные — заем  $Z_{i-1}$  из младшего разряда, уменьшаемое  $A_i$ , вычитаемое  $B_i$ ; выходные данные — разность  $R_i$  чисел, заем  $Z_i$ , полученный в  $i$ -м разряде. Разность чисел  $R_i$  определяется формулой

$$R_i = \bar{Z}_{i-1} \bar{A}_i B_i V \bar{Z}_{i-1} A_i \bar{B}_i V Z_{i-1} \bar{A}_i \bar{B}_i V Z_{i-1} A_i B_i = Z_{i-1} \oplus A_i \oplus B_i,$$

заем  $Z_i$  из старшего разряда в младший — формулой

$$Z_i = \bar{A}_i B_i V Z_{i-1} \bar{A}_i V Z_{i-1} B_i.$$

Арифметические операции в рассматриваемом устройстве выполняются в прямых кодах. Микрооперации  $R = \{R_1, R_2\}$  выполняются в блоке арифметических вычислений  $S$ : суммирование  $R_1 = y = \sum_{i=1}^n (a_i b_i) = (a_{n-1} + b_{n-1}) p^{n-1} + (a_{n-2} + b_{n-2}) p^{n-2} + \dots + (a_1 + b_1) p^1 + (a_0 + b_0) p^0$  и вычитание  $R_2 = y = \sum_{i=1}^n (a_i - b_i) = (a_{n-1} - b_{n-1}) p^{n-1} - (a_{n-2} - b_{n-2}) p^{n-2} - \dots - (a_1 - b_1) p^1 - (a_0 - b_0) p^0$

$$R_2 = y = \sum_{i=1}^n (a_i - b_i) = (a_{n-1} - b_{n-1}) p^{n-1} - (a_{n-2} - b_{n-2}) p^{n-2} - \dots - (a_1 - b_1) p^1 - (a_0 - b_0) p^0$$

в формате с фиксированной запятой. Операции сложения и вычитания могут быть представлены в виде совокупности нелинейных унарных операций и операций суммирования (табл. 1). Входные сигналы  $A$  и  $B$  суммирующего преобразователя распределяются в соответствии с законами  $f_A(\chi_1)$ ,  $f_B(\chi_2)$  и их взаимной корреляционной функцией —  $Q_{AB}(\tau)$ . Необходимо оценить дифференциальный закон распределения выходного сигнала  $f_Y(y)$ .

Таблица 1

Бинарные операции	Каноническое представление	
	$A>0, B<0$	при любых $A$ и $B$ из области определения
$S=A+B$	$S=A+B$	$S=A+B$
$S=A-B$	$Z=-B$ $S=A+Z$	$Z=-B$ $S=A+Z$

Интегральный закон распределения определяется как  $F_Y(y) = P(Y < y) = P(A + B < y)$ .

Обозначим через  $C_y\{A, B\}$  область значений  $A$  и  $B$ , удовлетворяющих условию  $\chi_1 + \chi_2 < y$ , т.е.  $C_y\{A, B\} = \{\chi_1 \in A, \chi_2 \in B \forall y : \chi_1 + \chi_2 < y\}$ , тогда интегральный закон распределения имеет вид

$$F_Y(y) = \iint_{C_y} f_\chi(\chi_1, \chi_2) d\chi_1 d\chi_2,$$

откуда

$$F_Y(y) = \int_{-\infty}^{\infty} \left[ \int_{-\infty}^{y-\chi_2} f_\chi(\chi_1, \chi_2) d\chi_2 \right] d\chi_1 \text{ или } F_Y(y) = \int_{-\infty}^{\infty} \left[ \int_{-\infty}^{y-\chi_1} f_\chi(\chi_1, \chi_2) d\chi_1 \right] d\chi_2.$$

Дифференцируя эти формулы, находим

$$f_Y(y) = \int_{-\infty}^{\infty} f_X(\chi_1, y - \chi_1) d\chi_1 \text{ и } f_Y(y) = \int_{-\infty}^{\infty} f_X(y - \chi_2, \chi_2) d\chi_2.$$

Двумерная плотность вероятности может быть представлена как

$$f_X(\chi_1, \chi_2) = f_A(\chi_1) f_B(\chi_2 / \chi_1),$$

где  $B$  — условный дифференциальный закон распределения при заданном  $\chi_1$ .

Для приближенного определения  $f_B(\chi_2 / \chi_1)$  составим уравнение линейной регрессии

$$m_{B/\chi_1} = m_B + r_{AB} \sqrt{\frac{D_B}{D_A}} \cdot (\chi_1 - m_{\chi_1}), \quad D_{\text{ост}} = D_B (1 - r_{AB}^2),$$

где  $m_{B/\chi_1}$  — математическое ожидание закона распределения  $B$  при заданном  $\chi_1$ ;  $m_B$  — безусловное математическое ожидание закона распределения  $B$ ;  $D_A$  — дисперсия;  $D_B$  — дисперсия закона распределения  $B$ ;  $D_{\text{ост}}$  — остаточная дисперсия  $B$ ;  $r_{AB} = \frac{R_{AB}}{\sqrt{D_A D_B}}$  — коэффициент корреляции  $A$  и  $B$ .

Сумма независимых случайных сигналов определяется по формуле  $r_{AB} = 0$ ; находим

$$f_B(\chi_B / \chi_A) = f_B(\chi_2), \quad f_A(\chi_1, \chi_2) = f_A(\chi_1) f_B(\chi_2), \quad f_Y(y) = \int_{-\infty}^{\infty} f_A(\chi_1) \cdot f_B(y - \chi_1) d\chi_1.$$

Получены результаты для независимых случайных сигналов. Закон распределения разности двух сигналов имеет вид:

$$f_{Z_1}(Z_1) = f_B(-Z_1),$$

$$f_Y(y) = \frac{1}{\sqrt{1-r_{AB}^2}} \int_{-\infty}^{\infty} f_A(\chi_1) f_B \left[ \frac{\chi_1 - y}{\sqrt{1-r_{AB}^2}} + \frac{r_{AB}}{\sqrt{1-r_{AB}^2}} \sqrt{\frac{D_B}{D_A}} \cdot (\chi_1 - m_A) + \left(1 - \frac{1}{\sqrt{1-r_{AB}^2}}\right) m_B \right] d\chi_1.$$

Разработан специализированный модуль вычислительной системы с параллельной схемой на элементах нейронной логики.

Блок ввода чисел используется для преобразования входных данных в двоичные коды  $A_{10} \rightarrow A_2, B_{10} \rightarrow B_2$  и для вычисления арифметической операции суммирования или вычитания (СВ). Он содержит шифратор (ШФ) и сумматоры по модулю два (рис. 1). Двоичные коды первого и второго чисел (ДПЧ, ДВЧ)  $A_2, B_2$ , знаковые разряды ЗнР  $A, B$  и код операции (КОП) формируются на выходе шифратора [9].

Выходные функции шифратора ( $f_1, f_2, f_3, f_4$ ) имеют вид:

$$\begin{aligned} f_1 &= y_1 \vee y_3 \vee y_5 \vee y_7 \vee y_9 \text{ в базисе И—НЕ } f_1 = \overline{\overline{y}_1 \& \overline{y}_3 \& \overline{y}_5 \& \overline{y}_7 \& \overline{y}_9}; \\ f_2 &= y_2 \vee y_3 \vee y_6 \vee y_7 \qquad \qquad \qquad f_2 = \overline{\overline{y}_2 \& \overline{y}_3 \& \overline{y}_6 \& \overline{y}_7}; \\ f_3 &= y_4 \vee y_5 \vee y_6 \vee y_7 \qquad \qquad \qquad f_3 = \overline{\overline{y}_4 \& \overline{y}_5 \& \overline{y}_6 \& \overline{y}_7}; \\ f_4 &= y_9 \vee y_8 \qquad \qquad \qquad f_4 = \overline{\overline{y}_9 \& \overline{y}_8}. \end{aligned}$$




Рис. 1

Промежуточный результат операции равен  
 $CB' = ЗнР B \oplus КОП$

и окончательно получаем

$$CB = CB' \oplus ЗнР A.$$

На входы каждой схемы сумматора-вычитателя поступают двоичные разряды чисел  $A_i$  и  $B_i$ , признак операции — сигнал СВ, перенос  $P_{i+1}$  из младших разрядов в старшие и заем  $Z_{i-1}$  из старших разрядов в младшие. Если сигнал СВ = 0, то  $S = A_n + B_n$ , если СВ = 1, то  $R = A_n - B_n$ . Знаковые разряды ЗнР  $A, B$ , сигнал СВ и сигнал заем из знакового разряда ЗмЗн Р, который поступает с выхода первого сумматора-вычитателя Сум-Выч<sub>1</sub>, поступают на входы схемы для определения знака результата (рис. 2). Вычислитель Сум-Выч<sub>1</sub> выполняет арифметические операции со старшими разрядами входных чисел. Сигнал заем из знакового разряда ЗмЗн Р определяется при вычитании чисел: если сигнал ЗмЗн Р = 0, то  $|A_n| \geq |B_n|$ , в этом случае разность  $R = A_n - B_n$ ; если сигнал ЗмЗн Р = 1, то  $|A_n| < |B_n|$ , в этом случае разность  $R = B_n - A_n$ . Для получения разности операндов необходимо поменять местами входные числа. Информационный сигнал результата РЕЗ является выходным сигналом блока.




Рис. 2

Нейроподобный элемент вычисляет сумму  $S_i$  и разность  $R_i$  входных двоичных разрядов; пороговый элемент вычисляет перенос  $P_i$  из младшего разряда в старший при суммировании и заем  $Z_i$  из старшего разряда в младший при вычитании, что и демонстрирует функциональная схема сумматора-вычитателя на нейроподобных элементах (рис. 3), а результат его работы представлен в табл. 2.




Рис. 3

Таблица 2

$P_{i+1}/Z_{i-1}$	$A$	$B$	$PEЗ_i$	$P_i$	$Z_i$
0	0	0	0	0	0
0	0	1	1	0	1
0	1	0	1	0	0
0	1	1	0	1	0
1	0	0	1	0	1
1	0	1	0	1	1
1	1	0	0	1	0
1	1	1	1	1	1

Сумма  $S_i$  и разность  $R_i$  двоичных разрядов вычисляются как


$$S_i/R_i = (P_{i+1}/Z_{i-1}) \oplus A_i \oplus B_i.$$

При суммировании перенос  $P_i$  из младшего разряда в старший и заем  $Z_i$  из старшего разряда в младший вычисляются по формулам

$$P_i/Z_i = (A_i/B_i \oplus CB) + P_{i+1}/Z_{i-1} + A_i + B_i \geq 2 = 1,$$

$$P_i/Z_i = (A_i/B_i \oplus CB) + P_{i+1}/Z_{i-1} + A_i + B_i < 2 = 0.$$

На рис. 4 представлена структурная схема алгоритма параллельного сумматора-вычитателя, построенного на элементах нейронной логики.



Шаг 1. Начало.

Шаги 2—3. Вводятся десятичные числа  $A_{10}$  и  $B_{10}$  со своими знаками ЗнР A и ЗнР B. Десятичные числа преобразуются в двоичные:  $A_{10} \rightarrow A_2$ ,  $B_{10} \rightarrow B_2$ , ЗнР A  $\rightarrow \{0,1\}$  и ЗнР B  $\rightarrow \{0,1\}$ . Команды программы:

```

Number-
Bin1=NumbersTenToBinary(number1.Text); numberBin2=NumbersTenToBinary(number2.Text);
Int CB=(numberSign1&numberSign2&KOP).
  
```

Арифметическая операция суммирования или вычитания определяется по формуле  $CB := \text{ЗнР } B \text{ КОП } \oplus \text{ЗнР } A$ .

Шаги 4—5. Двоичные разряды чисел  $A_2$ ,  $B_2$ , знаковые разряды двоичных чисел ЗнР A, ЗнР B, сигнал операции CB, сигнал заем из знакового разряда ЗмЗнР поступают на входы сумматора-вычитателя и схемы определения знака результата (СОЗР) numberBin1; numberBin2; Int CB. Фрагмент программы:

```
Public static int numberSign1; public static int numberSign2; int KOP; bool
test;
```

*Шаг 6.* Анализируется сигнал операции суммирования или вычитания СВ: если СВ=0, то вычисляется сумма чисел  $A_n, B_n$  и осуществляется переход к шагу 7, если СВ=1, то вычисляется разность чисел  $A_n, B_n$ .

Фрагмент программы:

```
Int CB=(numberSign1&numberSign2&KOP); if (CB==0);
answerBin=Addind(numberBin1, numberBin2); resultSign=numberSign1;
```

*Шаг 7.* Анализируется сигнал заем из знакового разряда ЗмЗнР, который вычисляется при вычитании чисел  $A_n$  и  $B_n$ . Если сигнал ЗмЗнР=0, это означает, что  $A_n > B_n$ , в этом случае вычисляется разность  $A_n - B_n$  и выполняется переход к шагу 9. Если сигнал ЗмЗнР=1, это означает, что  $A_n < B_n$ , в этом случае вычисляется разность  $B_n - A_n$  и осуществляется и переход к шагу 10. Программные команды:

```
Bool test = BinaryComparison(numberBin1, numberBin2);
```

*Шаг 8.* Если СВ=0, то вычисляется сумма чисел РЕЗ:=ДПЧ+ДВЧ. Знаковому разряду результата присваивается знаковый разряд первого числа Зн РЕЗ:=ЗнР  $A$ ; фрагмент программы:

```
AnswerBin = Adding(numberBin1, numberBin2); resultSign = numberSign1;
```

*Шаги 9—10.* Выполняется операция вычитания из большего числа по модулю меньшего числа. Знаковому разряду результата присваивается знаковый разряд большего числа. Если  $A_n > B_n$ , то вычисляется разность чисел  $A_n$  и  $B_n$ , РЕЗ:=ДПЧ–ДВЧ, Зн РЕЗ :=ЗнР  $A$ . Если  $A_n < B_n$ , то вычисляется разность чисел  $B_n$  и  $A_n$ , РЕЗ:=ДВЧ–ДПЧ, Зн РЕЗ :=ЗнР  $B$ . Операторы программы:

```
Else if(CB==1&&test) { answerBin = Subtraction(numberBin1, numberBin2);
resultSign= numberSign1} else { answerBin = Subtraction(numberBin2, number-
Bin1); resultSign= (numberSign2&KOP); }
```

*Шаг 11.* Результат и его знаковый разряд записываются в блок регистра результата (БРг Р);

```
Txt.Text = "Ответ в двоичной: "+ answerBin.Insert(0,resultSign+".");
```

*Шаг 12.* Конец.

При суммировании чисел знаковому разряду результата присваивается знаковый разряд первого числа Зн РЕЗ:=ЗнР  $A$ . При вычитании чисел знаковому разряду результата присваивается знаковый разряд большего числа по модулю. Знаковый разряд результата определяется по формуле

$$\text{ЗнР РЕЗ} = (\text{СВ} \& \text{ЗмЗнР}) \& \text{ЗнР } B V \overline{(\text{СВ} \& \text{ЗмЗнР}) \& \text{ЗнР } A},$$

сигнал суммирования-вычитания СВ — по формуле

$$\text{СВ} = (\text{ЗнР } B \oplus \text{КОП}) \oplus \text{ЗнР } A.$$

Арифметический вычислитель с параллельной схемой на элементах нейронной логики, построенный на основе каскадного соединения  $n$  полных одноразрядных сумматоров-вычитателей [15, 16], выполняет арифметические операции сложения и вычитания двоичных чисел. Результатом выполнения операций является сумма  $S$  или разность  $R$  двоичных чисел (табл. 3) [17].

Регистр результата содержит некоторое число двоичных триггеров (количество разрядов), необходимых для получения результата. По сигналу разрешения на запись двоичные биты записываются параллельно в регистр результата [18].

Таблица 3

Число $A_{10}$	Число $B_{10}$	Число $A_2$	Число $B_2$	Код операции	$W_2$	$W_{10}$
68	29	0,1000100	0,0011101	Суммирование	0,1100001	97
36	47	0,0100100	0,0101111	Вычитание	1,0001011	-11
-43	57	1,0101011	0,0111001	Суммирование	0,0001110	14
-88	-49	1,1011000	1,0110001	Вычитание	1,0100111	-39
55	-34	0,0110111	1,0100010	Суммирование	0,010101	21
-29	42	1,0011101	0,0101010	Вычитание	1,1000111	-71
-87	-16	1,1010111	1,0010000	Суммирование	1,1100111	-103
65	38	0,1000001	0,0100110	Вычитание	0,0011011	27
-75	-31	1,1001011	1,0011111	Суммирование	1,1101010	-106
-68	25	1,1000100	0,0011001	Вычитание	1,1011101	-93
77	-34	0,1001101	1,0100010	Суммирование	0,0101011	43
-56	-71	1,0111000	1,1000111	Вычитание	0,0001111	15
49	32	0,0110001	0,0100000	Суммирование	0,1010001	81
-61	28	1,0111101	0,0011100	Вычитание	1,1011001	-89
-43	-22	1,0101011	1,0010110	Суммирование	1,1000001	-65
51	-10	0,0110011	1,0001010	Вычитание	0,0111101	61
-29	40	1,0011101	0,0101000	Суммирование	0,0001011	11
107	89	0,1101011	0,1011001	Вычитание	0,0010010	18
-54	-33	1,0110110	1,0100001	Суммирование	1,1010111	-87
21	88	0,0010101	0,1011000	Вычитание	1,1000011	-67
-102	82	1,1100110	0,1010010	Суммирование	1,0010100	-20
-94	-101	1,1011110	1,1100101	Вычитание	0,0000111	7

П р и м е ч а н и е . Индексы „10“ и „2“ при числах  $A$ ,  $B$  и  $W$  соответствуют десятичной и двоичной системам счисления;  $W$  — результат.

Время выполнения арифметических операций последовательным и параллельным вычислителями ( $T_{\text{посл}}$ ,  $T_{\text{пар}}$ ) показано в табл. 4.

Таблица 4

Число входных пар двоичных чисел	$T_{\text{посл}}, \text{ нс}$	$T_{\text{пар}}, \text{ нс}$
0	0	0
1	1	1
4	3	2
8	5	3
16	8	5
32	14	9

На графике, показанном на рис. 5, отображены результаты сравнительного анализа времени задержки для вычисления суммы и разности входных чисел с помощью последовательного и параллельного вычислителей.




Рис. 5

Итак, арифметический вычислитель, выполняющий операции сложения и вычитания чисел в формате с фиксированной запятой в прямом коде, может быть использован в задачах вычислительной модульной системы для разработки специализированных микропроцессоров. Сумма и разность одноразрядных двоичных чисел вычисляются на нейроподобном

элементе по формуле  $S_i/R_i = (P_{i+1}/Z_{i-1}) \oplus A_i \oplus B_i$ . Перенос  $P_i$  из младшего разряда в старший выполняется по формуле  $P_i = A_i B_i V P_{i+1} A_i V P_{i+1} B_i$ . Заем  $Z_i$  из старшего разряда в младший вычисляется по формуле  $Z_i = \overline{A}_i B_i V Z_{i-1} \overline{A}_i V Z_{i-1} B_i$ . Перенос и заем вычисляются на нейроноподобном и пороговом элементах, которые не приводят к аппаратным избыточным затратам цифровых специализированных модулей.

Скорость вычислений арифметических операций увеличивается за счет реализации параллелизма при обработке данных, а также использования нейроноподобных элементов, что позволяет снизить аппаратную сложность устройств.

#### СПИСОК ЛИТЕРАТУРЫ

1. Шевченко В. П. Вычислительные системы, сети и телекоммуникации. М.: КноРус, 2022. 288 с.
2. Старков В. В. Архитектура персонального компьютера. Организация, устройство, работа. М.: Горячая линия — Телеком, 2022. 538 с.
3. Киселев С. В. и др. Аппаратные средства персонального компьютера. М.: Академия, 2022. 625 с.
4. Трофимов В. В. и др. Информационные технологии. М.: Юрайт, 2022. 392 с.
5. Кузин А. В., Демин В. М. Компьютерные сети. М.: Форум, Инфра-М, 2022. 385 с.
6. Шелухин О. И., Тенякишев А. М., Осин А. В. Моделирование информационных систем. М.: Радиотехника, 2022. 368 с.
7. Рыбин С. В. Дискретная математика и информатика. СПб: Лань, 2022. 749 с.
8. Гуревич Д. З., Елизаров В. Н., Рувинский Б. И. Большие интегральные схемы и вычислительные машины четвертого поколения. М.: ЦНИИ „Электроника“, 2021. 783 с.
9. Пат. 2780299 РФ. Параллельный сумматор-вычитатель на элементах нейронной логики / С. С. Шевелев. Опубл. 21.09.2022. Бюл. № 7.
10. Гаврилов М. В., Клинов В. А. Информатика и информационные технологии. М.: Юрайт, 2022. 383 с.
11. Ходгал Д. С. Анализ и диагностика компьютерных сетей. М.: ЛОРИ, 2022. 350 с.
12. Хлебников А. А. Информационные технологии. М.: КноРус, 2021. 466 с.
13. Микропроцессоры и микропроцессорные системы / Под ред. В. Б. Смолова. М.: Радио и связь, 2022. 328 с.
14. Шевелев С. С. Устройство выполнения логических и арифметических операций // Программная инженерия. 2021. Т. 12, № 7. С. 350—357. DOI: 10.17587/prin.12.350—357.
15. Трояновский В. М. Информационно-управляющие системы и прикладная теория случайных процессов. М.: Гелиос АРВ, 2022. 390 с.
16. Никитюк Н. М. Микропроцессоры и микро-ЭВМ. Применение в приборостроении и в научных исследованиях. М.: Энергоиздат, 2022. 168 с.
17. Shevelev S. S. Parallel-sequential adder-subtractor with the highest digits forward on neurons // Neurocomputers. 2021. Vol. 23, N 3. P. 5—14. DOI: 10.18127/j19998554-202103-01/.
18. Пат. 2739343 РФ. Устройство поразрядного вычисления логических и арифметических операций / С. С. Шевелев. Опубл. 23.12.2020. Бюл. № 36.

#### *Сведения об авторах*

**Виталий Семенович Титов**

— д-р техн. наук, профессор; Юго-Западный государственный университет, кафедра вычислительной техники; E-mail: vt.swsu@yandex.ru

**Сергей Степанович Шевелев**

— канд. техн. наук, доцент; Юго-Западный государственный университет, кафедра информационной безопасности; E-mail: schewelev@mail.ru

Поступила в редакцию 02.06.2023; одобрена после рецензирования 24.08.2023; принята к публикации 27.09.2023.

## REFERENCES

1. Shevchenko V.P. *Vychislitel'nyye sistemy, seti i telekommunikatsii* (Computing Systems, Networks and Telecommunications), Moscow, 2022, 288 p. (in Russ.)
2. Starkov V.V. *Arkhitektura personal'nogo komp'yutera. Organizatsiya, ustroystvo, rabota* (Architecture of a Personal Computer. Organization, Arrangement, Work), Moscow, 2022, 538 p. (in Russ.)
3. Kiselev S.V. et al. *Apparatnyye sredstva personal'nogo komp'yutera* (Personal Computer Hardware), Moscow, 2022, 625 p. (in Russ.)
4. Trofimov V.V. et al. *Informatsionnyye tekhnologii* (Information Technologies), Moscow, 2022, 392 p. (in Russ.)
5. Kuzin A.V., Demin V.M. *Komp'yuternyye seti* (Computer Networks), Moscow, 2022, 385 p. (in Russ.)
6. Shelukhin O.I., Tenyakshev A.M., Osin A.V. *Modelirovaniye informatsionnykh sistem* (Modeling of Information Systems), Moscow, 2022, 368 p. (in Russ.)
7. Rybin S.V. *Diskretnaya matematika i informatika* (Discrete Mathematics and Computer Science), St. Petersburg, 2022, 749 p.
8. Gurevich D.Z., Elizarov V.N., Ruvinsky B.I. *Bol'shiye integral'nyye skhemy i vychislitel'nyye mashiny chetvertogo pokoleniya* (Large Integrated Circuits and Computing Machines of the Fourth Generation), Moscow, 2021, 783 p. (in Russ.)
9. Patent RU 2780299, *Parallel'nyy summator-vychitatel' na elementakh nevronnoy logiki* (Parallel Adder-Subtractor on Elements of Neural Logic), S. Shevelev, Patent application no. 2020129345, Priority 04.09.2020, Published 21.09.2022, Bulletin 7. (in Russ.)
10. Gavrilov M.V., Klimov V.A. *Informatika i informatsionnyye tekhnologii* (Informatics and Information Technologies), Moscow, 2022, 383 p. (in Russ.)
11. Haugdahl J.S. *Network Analysis and Troubleshooting*, Addison-Wesley Professional, 2000, 357 p.
12. Khlebnikov A.A. *Informatsionnyye tekhnologii* (Information Technologies), Moscow, 2021, 466 p. (in Russ.)
13. Smolov V.B., ed., *Mikroprotsessory i mikroprotsessornyye sistemy* (Microprocessors and Microprocessor Systems), Moscow, 2022, 328 p. (in Russ.)
14. Shevelev S.S. *Programmnaya Ingeneria*, 2021, no. 7(12), pp. 350–357, DOI: 10.17587/prin.12.350-357.
15. Troyanovsky V.M. *Informatsionno-upravlyayushchiye sistemy i prikladnaya teoriya sluchaynykh protsessov* (Information and Control Systems and Applied Theory of Random Processes), Moscow, 2022, 390 p. (in Russ.)
16. Nikityuk N.M. *Mikroprotsessory i mikro-EVM. Primeneniye v priborostroyenii i v nauchnykh issledovaniyakh* (Microprocessors and Microcomputers. Application in Instrumentation and Scientific Research), Moscow, 2022, 168 p. (in Russ.)
17. Shevelev S.S. *Neurocomputers*, 2021, no. 3(23), pp. 5–14, DOI: <https://doi.org/10.18127/j19998554-202103-01>.
18. Patent RU 2739343, *Ustroystvo porazryadnogo vychisleniya logicheskikh i arifmeticheskikh operatsiy* (Device for Bit-by-Bit Calculation of Logical and Arithmetic Operations), S. Shevelev, Patent application no. 2020129326, Priority 04.09.2020, Published 23.12.2020, Bulletin 36. (in Russ.)

**Data on authors**

- Vitaliy S. Titov** — Dr. Sci., Professor; The Southwest State University, Department of Computer Technique; E-mail: vt.swsu@yandex.ru
- Sergey S. Shevelev** — PhD, Associate Professor; The Southwest State University, Department of Information Security; E-mail: schewelew@mail.ru

Received 02.06.2023; approved after reviewing 24.08.2023; accepted for publication 27.09.2023.

# ОПТИЧЕСКИЕ И ОПТИКО-ЭЛЕКТРОННЫЕ ПРИБОРЫ И КОМПЛЕКСЫ

## OPTICAL AND OPTO-ELECTRONIC INSTRUMENTS AND COMPLEXES

УДК 621.391.63:681.7.068  
DOI: 10.17586/0021-3454-2023-66-11-960-967

### ЭФФЕКТИВНАЯ ФОТОЧУВСТВИТЕЛЬНАЯ ПОВЕРХНОСТЬ КРЕМНИЕВЫХ ФОТОУМНОЖИТЕЛЕЙ

И. Р. ГУЛАКОВ, А. О. ЗЕНЕВИЧ, О. В. КОЧЕРГИНА\*

*Белорусская государственная академия связи, Минск, Беларусь*  
\*  
*[o.kochergina@bsac.by](mailto:o.kochergina@bsac.by)*

**Аннотация.** Представлены результаты исследования по определению эффективной площади фоточувствительной поверхности кремниевых фотоумножителей (SiФЭУ) при рабочем напряжении питания, а также установлению зависимости этой характеристики от приложенного напряжения питания. Для проведения исследования выбраны кремниевые фотоумножители КОФ5-1035 (Беларусь), Ketek RM 3325 и ON Semi FC 30035 (Германия). Предложена экспериментальная установка, с помощью которой определено, что увеличение напряжения питания приводит к увеличению площади эффективной фоточувствительной поверхности SiФЭУ. Получено, что максимальное значение чувствительности при рабочем напряжении наблюдается в центральной части фоточувствительной поверхности и симметрично уменьшается при приближении пятна оптического зонда к краю этой поверхности. Полученные результаты могут быть применены при создании приборов для регистрации оптического излучения видимого диапазона на базе кремниевых фотоумножителей.

**Ключевые слова:** кремниевый фотоумножитель, фототок, чувствительность, неравномерность чувствительности, перенапряжение, эффективная фоточувствительная поверхность

**Ссылка для цитирования:** Гулаков И. Р., Зеневич А. О., Кочергина О. В. Эффективная фоточувствительная поверхность кремниевых фотоумножителей // Изв. вузов. Приборостроение. 2023. Т. 66, № 11. С. 960—967. DOI: 10.17586/0021-3454-2023-66-11-960-967.

### EFFECTIVE PHOTOSENSITIVE SURFACE OF SILICON PHOTOMULTIPLIERS

I. R. Gulakov, A. O. Zenevich, O. V. Kochergina\*

*Belarusian State Academy of Communications, Minsk, Belarus*  
\*  
*[o.kochergina@bsac.by](mailto:o.kochergina@bsac.by)*

**Abstract.** Research has been carried out to determine the effective area of the photosensitive surface of silicon photomultipliers (SiPM) at the operating supply voltage, as well as to establish the dependence of this characteristic on the applied supply voltage. Silicon photomultipliers KOF5-1035 (Belarus), Ketek RM 3325 and ON Semi FC 30035 (Germany) are selected for the study. Application of developed experimental setup makes it possible to reveal that an increase in the supply voltage leads to an increase in the area of the effective photosensitive surface of the SiPM. It is found that the maximum value of sensitivity at a given operating voltage is observed in the central part of the photosensitive surface and decreases symmetrically as the spot of the optical probe approaches the surface edge. The results obtained can be used to create devices for detecting optical radiation in the visible range based on silicon photomultipliers.

**Keywords:** silicon photomultiplier, photocurrent, sensitivity, sensitivity heterogeneity, overvoltage, effective photosensitive surface

**For citation:** Gulakov I. R., Zenevich A. O., Kochergina O. V. Effective photosensitive surface of silicon photomultipliers. *Journal of Instrument Engineering*. 2023. Vol. 66, N 11. P. 960—967 (in Russian). DOI: 10.17586/0021-3454-2023-66-11-960-967.

**Введение.** Для решения ряда научных и технических задач требуется регистрация сверхслабых световых потоков. В последние годы для этого используются кремниевые многоэлементные лавинные фотоприемники — кремниевые фотоумножители (SiФЭУ) [1—3], имеющие ряд преимуществ перед другими фотоприемниками [4, 5]. Так, по сравнению с электровакуумными фотоэлектронными умножителями кремниевые фотоумножители более компактны, нечувствительны к магнитным полям, имеют высокую механическую прочность и лучшую чувствительность к видимой области спектра, также для работы SiФЭУ необходимы меньшие напряжения питания. По сравнению с одноэлементными лавинными фотоприемниками кремниевые фотоумножители обладают такими преимущества, как более высокий коэффициент усиления и большая площадь фоточувствительной поверхности [6—10].

Однако на данный момент не все характеристики SiФЭУ изучены в полной мере. Одной из наиболее важных характеристик кремниевого фотоумножителя является эффективная площадь фоточувствительной поверхности. Знание этой характеристики важно при определении диаметра светового пятна, формируемого оптической системой на фоточувствительной поверхности кремниевого умножителя для обеспечения его максимальной чувствительности. В этой связи цель настоящей статьи — определение эффективной площади фоточувствительной поверхности кремниевого фотоумножителя при рабочем напряжении питания, а также установление зависимости этой характеристики от приложенного напряжения питания.

**Экспериментальная установка и методика измерений.** Для проведения исследований были выбраны кремниевые фотоумножители КОФ5-1035 (Беларусь), Ketek PM 3325 и ON Semi FC 30035 (Германия), имеющие схожую полупроводниковую структуру и параметры [11].

Исследования выполнялись на экспериментальной установке, структурная схема которой представлена на рис. 1, где И — источник оптического излучения, ОС — оптическая система, Б — блок питания, А — амперметр, В — вольтметр, Ф — кремниевый фотоумножитель, Д — дозиметр оптического излучения, З — полупрозрачное зеркало, Н — набор нейтральных светофильтров, О — диафрагма,  $R_n$  — сопротивление нагрузки, К — координатный столик, 1 и 2 — индикаторные микрометры.




Рис. 1

Установка функционирует следующим образом. Источник оптического излучения И — полупроводниковый лазер с длиной волны 470 нм, соответствующей максимуму спектральной чувствительности кремниевых фотоумножителей [11], — направляет оптическое

излучение постоянной интенсивности на полупрозрачное зеркало З. При этом излучение проходит через набор нейтральных светофильтров Н, с помощью которого обеспечивается ослабление интенсивности оптического излучения в интервале от  $10^{-5}$  до  $10^{-10}$  Вт/см<sup>2</sup>.

Полупрозрачное зеркало используется для разделения оптического излучения на два пучка равной интенсивности, один из которых подается на дозиметр оптического излучения Д марки ЛД-07, а второй через диафрагму О поступает в оптическую систему. Оптическая система формирует на фоточувствительной поверхности кремниевого фотоумножителя Ф световое пятно круглой формы оптического зонда. Площадь этого пятна не превышает 0,2 площади фоточувствительной поверхности SiФЭУ.

Кремниевый фотоумножитель располагается на координатном столике К. С помощью индикаторных микрометров 1 и 2 пятно оптического зонда можно перемещать в горизонтальной плоскости в двух направлениях, перпендикулярных друг другу. Блок питания Б позволяет регулировать напряжение питания  $U_n$ , для измерения которого используется вольтметр В. Последовательно с кремниевым фотоумножителем включено сопротивление нагрузки  $R_n = 1$  кОм, используемое для ограничения тока, протекающего через SiФЭУ.

Измерения темнового тока  $I_t$  SiФЭУ выполняются при закрытой диафрагме, в случае открытой диафрагмы регистрируется общий ток  $I$ . По значению фототока  $I_\phi$ , вычисляемого как  $I_\phi = I - I_t$ , и интенсивности оптического излучения  $J$  рассчитывается чувствительность SiФЭУ в каждой точке фоточувствительной поверхности [12]:

$$S = I_\phi / J. \quad (1)$$

Интенсивность оптического излучения  $J$  выбиралась так, чтобы фототок при полном попадании светового пятна оптического зонда на фоточувствительную поверхность не менее чем в 100 раз превышал темновой ток и находился в пределах динамического диапазона исследуемых SiФЭУ (ГОСТ Р 59607-2021); значение интенсивности составляло  $8 \cdot 10^{-8}$  Вт/см<sup>2</sup>.

Неравномерность чувствительности фотоприемника определялась согласно методике, описанной в [13]. Испытуемый фотоприемник перемещают в заданном направлении, изменяя таким образом местонахождение светового пятна оптического зонда на его фоточувствительной поверхности. Далее определяют местонахождение светового пятна, при котором наблюдается максимальное значение фототока, после чего регистрируют координаты зонда и значение фототока. Затем последовательно перемещают фотоприемник в разные стороны от этого положения, измеряя фототок и фиксируя координаты светового пятна оптического зонда до достижения им края фоточувствительной поверхности фотоприемника.

В процессе исследования измерялась зависимость чувствительности  $S$  SiФЭУ от местонахождения светового пятна оптического зонда, по которой определялись среднее значение чувствительности  $S_{cp}$  и величина  $\Delta S = S_{max} - S_{min}$ , где  $S_{max}$  и  $S_{min}$  — максимальная и минимальная чувствительности соответственно.

Неравномерность чувствительности  $\delta$  SiФЭУ определялась по формуле

$$\delta = \Delta S / S_{cp}. \quad (2)$$

Эффективная площадь  $A_{\phi}$  для квадратной формы фоточувствительной поверхности определялась согласно выражению

$$A_{\phi} = [(x_2 - x_1)(x'_2 - x'_1)], \quad (3)$$

где  $x_2$ ,  $x_1$  и  $x'_1$ ,  $x'_2$  — координаты перемещения координатного столика в двух взаимно перпендикулярных направлениях.

Изменения местоположения светового пятна оптического зонда выполнялось по взаимно перпендикулярным осям симметрии фоточувствительной поверхности. При этом коорди-

наны  $x_1$  и  $x'_1$  соответствуют точке положения пятна оптического зонда, для которого наблюдается максимальное значение чувствительности  $S_{\max}$ , а координаты  $x_2$  и  $x'_2$  — точке положения пятна оптического зонда, для которого значение чувствительности составляет  $0,9S_{\max}$ .

Шаг, с которым изменялось местонахождение светового пятна оптического зонда, подбирался таким, чтобы число точек измерения было не менее 10.

Исследуемые кремниевые умножители имеют различные напряжения лавинного пробоя  $U_{\text{пр}}$ . Поэтому для сравнительного анализа их характеристик применяется перенапряжение:  $\Delta U = U_{\text{п}} - U_{\text{пр}}$ . Исследования проводились для перенапряжений  $\Delta U = -0,5 \dots 1,0$  В. При больших значениях  $\Delta U$  происходит значительный рост темнового тока, что может привести к тепловому пробою SiФЭУ. Для меньших значений  $\Delta U$  коэффициент усиления кремниевого умножителя близок к единице. Значение напряжения пробоя  $U_{\text{пр}}$  устанавливалось по вольт-амперной характеристике SiФЭУ при закрытой диафрагме на основании методики [14]. Для исследуемых фотоприемников значения  $U_{\text{пр}}$  следующие: ON Semi FC 30035 — 24,7 В, Ketek PM 3325 — 27,0 В и КОФ5-1035 — 30,0 В.

Измерения выполнялись при температуре  $T = 293$  К. В процессе измерения неравномерности чувствительности поверхности кремниевого фотоумножителя выполнялись все требования по расходимости светового пятна оптического зонда и погрешности измерений, установленные стандартом [12].

**Результаты измерений. Обсуждение.** Зависимости чувствительности  $S$  от местонахождения светового пятна оптического зонда на фоточувствительной поверхности для исследуемых SiФЭУ показаны на рис. 2. Зависимости получены для перенапряжения  $\Delta U = 0$ , т.е. для напряжений лавинного пробоя SiФЭУ. Такое значение  $\Delta U$  было выбрано, поскольку отношение сигнал/шум для исследуемых фотоприемников имеет максимальное значение [15]. Отметим, что напряжение пробоя считалось рабочим напряжением для данных SiФЭУ.

На рис. 2, *a* представлена типичная зависимость чувствительности SiФЭУ от местонахождения ( $r$ ) пятна оптического зонда для КОФ5-1035, для Ketek PM 3325 и ON Semi FC 30035 зависимости аналогичны. Представленная на рис. 2, *б* показана зависимость, построенная вдоль одной из диагоналей. Так, для Ketek PM 3325 и ON Semi FC 30035 (кривые 1, 2) диагональ составляет 4,2 мм, а для КОФ5-1035 (кривая 3) — 1,76 мм.




Рис. 2

Максимальное значение чувствительности наблюдается в центре фоточувствительной поверхности и уменьшается при приближении пятна оптического зонда к ее краю. Так,  $S_{\max} = 245, 223$  и  $144$  кА/Вт и  $S_{\min} = 173, 168$  и  $107$  кА/Вт для Ketek PM 3325, ON Semi FC 30035 и КОФ5-1035 соответственно. Иными словами, чувствительность в пределах фоточувствительной поверхности уменьшалась не более чем на 30 % для всех исследуемых фотоприемников. Изменение чувствительности в зависимости от местоположения пятна оптического зонда связано с тем, что напряжение лавинного пробоя отдельных ячеек SiФЭУ может отличаться.

Это приводит к тому, что при одном и том же напряжении питания на каждой ячейке будет разное значение перенапряжения. Чувствительность SiФЭУ, а значит, и каждой его ячейки зависит от перенапряжения [12]. Снижение чувствительности ячеек SiФЭУ, находящихся ближе к краю фоточувствительной поверхности, определяется, по-видимому, недостатками технологий изготовления этих фотоприемников.

На рис. 3 представлена зависимость неравномерности чувствительности  $\delta$  SiФЭУ от перенапряжения  $\Delta U$ : 1 — ON Semi FC 30035, 2 — КОФ5-1035, 3 — Ketek PM 3325. Увеличение перенапряжения приводит к уменьшению неравномерности чувствительности. Это объясняет тем, что с ростом перенапряжения для все большего числа ячеек напряжение питания SiФЭУ начинает превышать напряжение их пробоя. В результате значительно повышается чувствительность ячейки к оптическому излучению и уменьшается неравномерность чувствительности SiФЭУ. Для анализа зависимости  $\delta(\Delta U)$  введен коэффициент  $\Delta\delta/\Delta U_n$ , где  $\Delta\delta$  — изменение значения  $\delta$  при изменении перенапряжения на  $\Delta U_n$ . Тогда при  $\Delta U < 0$  отношение  $\Delta\delta/\Delta U_n = 0,04, 0,08$  и  $0,18 \text{ B}^{-1}$  для Ketek PM 3325, ON Semi FC 30035 и КОФ5-1035 соответственно; при  $\Delta U > 0$  величина  $\Delta\delta/\Delta U_n = 0,02 \text{ B}^{-1}$  для всех фотоприемников.




Рис. 3

Таким образом, наиболее сильная зависимость  $\delta$  от перенапряжения проявляется при  $\Delta U < 0$  для всех исследуемых SiФЭУ. Это связано с тем, что при  $\Delta U = -0,5 \text{ В}$  приблизительно для 45 % ячеек напряжение питания SiФЭУ превышает напряжения их пробоя, а при  $\Delta U = 0$  их становится приблизительно 65 %. В диапазоне  $0,0 < \Delta U \leq 1,0 \text{ В}$  количество ячеек, для которых напряжение питания SiФЭУ превышает напряжения их пробоя, изменяется от 65 до 75 %.

Наибольшие значения  $S_{\max}$  и  $S_{\min}$  соответствуют Ketek PM 3325, а наименьшие — КОФ5-1035 на всей площади фоточувствительной поверхности исследуемых фотоприемников.

Результаты исследования эффективной площади фоточувствительной поверхности исследуемых SiФЭУ приведены в таблице, где  $A$  — полная площадь фоточувствительной поверхности.

Тип фотоприемника	$\Delta U, \text{ В}$	$A_{\phi}, \text{ мм}^2$	$A, \text{ мм}^2$	$A_{\phi}/A$
Ketek PM 3325	-0,5	4,2	9,00	0,46
	0,0	5,8		0,65
	1,0	6,9		0,76
ON Semi FC 30035	-0,5	4,0	9,00	0,44
	0,0	5,8		0,65
	1,0	6,8		0,76
КОФ5-1035	-0,5	0,6	1,56	0,41
	0,0	1,0		0,64
	1,0	1,2		0,77

На рис. 4 представлена зависимость отношения  $A_{\phi}/A$  от перенапряжения  $\Delta U$ : 1 — КОФ5-1035; 2 — ON Semi FC 30035; 3 — Ketek PM 3325.




Рис. 4

Анализ графиков показывает, что рост перенапряжения приводит к увеличению площади эффективной фоточувствительной поверхности, а значит, и количества ячеек, для которых напряжение питания SiФЭУ превышает напряжения их пробоя.

Таким образом, значения отношения  $A_{\text{эф}}/A$  для всех исследуемых фотоприемников примерно одинаковы при постоянном значении перенапряжения.

**Заключение.** По результатам экспериментального изучения важных характеристик кремниевых фотоумножителей определено следующее:

- эффективная площадь фоточувствительной поверхности исследуемых SiФЭУ при рабочем напряжении составила  $5,8 \text{ мм}^2$  для Ketek PM 3325 и ON Semi FC 30035 и  $1,0 \text{ мм}^2$  для КОФ5-1035;

- рост напряжения питания приводит к увеличению площади эффективной фоточувствительной поверхности;

- максимальное значение чувствительности при рабочем напряжении SiФЭУ наблюдается в центральной части фоточувствительной поверхности и симметрично уменьшается при приближении пятна оптического зонда к краю этой поверхности;

- при напряжении питания SiФЭУ, равном напряжению лавинного пробоя, площадь фоточувствительной поверхности, чувствительность в которой уменьшается не более чем на 10 % от максимального значения, составляет 64 – 65 % для всех исследуемых SiФЭУ;

- во всем диапазоне исследуемых напряжений чувствительность исследуемых SiФЭУ снижалась не более чем на 32 % от своего максимального значения; увеличение перенапряжения приводит к уменьшению неравномерности чувствительности SiФЭУ и увеличению эффективной площади фоточувствительной поверхности.

#### СПИСОК ЛИТЕРАТУРЫ

1. Клемин С. и др. Кремниевый фотоэлектронный умножитель. Новые возможности // Электроника: Наука, Технология, Бизнес. 2007. № 8. С. 80—86.
2. Stagliano M., Abegão L., Chiericia A., d'Errico F. Silicon photomultiplier current and prospective applications in biological and radiological photonics // EPH — Intern. Journal of Science and Engineering. 2018. Vol. 4, iss. 10. P. 21.
3. Modi M. N., Daie K., Turner G. C., Podgorski K. Two-photon imaging with silicon photomultipliers // Opt. Express. 2019. Vol. 27, N 24. P. 35830.
4. Соболева Н. А., Меламид А. Е. Фотоэлектронные приборы. М.: Высш. школа, 1974. 376 с.
5. Гулаков И. Р., Холондырев С. В. Метод счета фотонов в оптико-физических измерениях. Минск: Университетское, 1989. 256 с.
6. Лебедев А. И. Физика полупроводниковых приборов. М.: Физмалит, 2008. 488 с.
7. Войцеховский А. В., Ижнин И. И., Савчин В. П., Вакив Н. М. Физические основы полупроводниковой фотоэлектроники. Томск: Изд. дом Томск. гос. ун-та, 2013. 560 с.

8. О'Нилл К., Павлов Н., Джексон К. Новый кремниевый фотоумножитель с быстродействующим выходом компании SensL // Фотоника. 2013. № 1 (37). С. 76—83.
9. Дудник А. В., Курбатов Е. В., Валтонен Э. Амплитудные и скоростные характеристики многопиксельных счетчиков фотонов S10931-050P и S10931-100P производства „Hamamatsu Photonics“ // Journal of Kharkiv University: Physical series „Nuclei, Particles, Fields“. 2012. Vol. 991, iss. 1 /53/. P. 69—74.
10. Ramadhani E. A. Mini Review of Lifi Technology: Security Issue // Intern. Journal of Computer and Information System (IJCIS) Peer Reviewed. 2022. Vol. 03, iss. 03. P. 90—93.
11. Исследование характеристик матричных лавинных фотоприемников в режиме счета фотонов / И. Р. Гулаков, А. О. Зеневич, Е. В. Новиков, О. В. Кочергина, А. А. Лагутик // Успехи прикладной физики. 2021. Т. 9, № 3. С. 216—223.
12. Гулаков И. Р., Зеневич А. О., Кочергина О. В. Спектральные характеристики кремниевых фотоэлектронных умножителей // Успехи прикладной физики. 2021. Т. 9, № 2. С. 164—171.
13. Зеневич А. О., Кочергина О. В. Исследование динамического диапазона кремниевых фотоэлектронных умножителей // Изв. вузов. Электроника. 2021. Т. 26, № 1. С. 30—39.
14. Гулаков И. Р., Зеневич А. О. Фотоприемники квантовых систем. Минск: УО ВГКС, 2012. 276 с.
15. Асаенок М. А., Зеневич А. О., Кочергина О. В., Новиков Е. В., Сорока С. А. Работа кремниевых фотоэлектронных умножителей со структурой  $p^+ - p - n^+$  в режиме одноквантовой регистрации // Весці Нацыянальнай акадэміі навук Беларусі. Серыя фізіка-тэхнічных навук. 2020. Т. 65, № 3. С. 349—356.

#### **Сведения об авторах**

**Иван Романович Гулаков**

— д-р техн. наук, профессор; Белорусская государственная академия связи, кафедра математики и физики; E-mail: gulakov@bsu.by

**Андрей Олегович Зеневич**

— д-р техн. наук, профессор; Белорусская государственная академия связи; ректор; E-mail: a.zenevich@bsac.by

**Ольга Викторовна Кочергина**

— Белорусская государственная академия связи, кафедра радио и информационных технологий; преподаватель; E-mail: o.kochergina@bsac.by

Поступила в редакцию 23.06.2023; одобрена после рецензирования 08.07.2023; принята к публикации 27.09.2023.

#### **REFERENCES**

1. Klemin S. et al. *Electronics: Science, Technology, Business*, 2007, no. 8, pp. 80—86. (in Russ.)
2. Stagliano M., Abegão L., Chiericia A., and d'Errico F. *EPH - Intern. J. of Science and Engineering*, 2018, no. 10(4), pp. 21.
3. Modi M.N., Daie K., Turner G.C., Podgorski K. *Optics express*, 2019, no. 24(27), pp. 35830.
4. Soboleva N.A., Melamid A.E. *Fotoelektronnyye pribory* (Photoelectronic Devices), Moscow, 1974, 376 p. (in Russ.)
5. Gulakov I.R., Kholondyrev S.V. *Metod scheta fotonov v optiko-fizicheskikh izmereniyakh* (Photon Counting Method in Optical-Physical Measurements), Minsk, 1989, 256 p. (in Russ.)
6. Lebedev A.I. *Fizika poluprovodnikovykh priborov* (Physics of Semiconductor Devices), Moscow, 2008, 488 p. (in Russ.)
7. Voytsekhovskiy A.V., Izhnin I.I., Savchin V.P., Vakiv N.M. *Fizicheskiye osnovy poluprovodnikovoy fotoelektroniki* (Physical Foundations of Semiconductor Photoelectronics), Tomsk, 2013, 560 p. (in Russ.)
8. O'Neill K., Pavlov N., Jackson C. *Photonics Russia*, 2013, no. 1(37), pp. 76—83. (in Russ.)
9. Dudnik A.V., Kurbatov E.V., Valtonen E. *Journal of Kharkiv University: Physical series «Nuclei, Particles, Fields»*, 2012, no. 1(991), pp. 69—74.
10. Ramadhani E. *Intern. J. of Computer and Information System (IJCIS) Peer Reviewed*, 2022, no. 03(03), pp. 90—93.
11. Gulakov I.R., Zenevich A.O., Novikov E.V., Kochergina O.V., Lagutik A.A. *Advances in Applied Physics*, 2021, no. 3(9), pp. 216—223. (in Russ.)
12. Gulakov I.R., Zenevich A.O., Novikov E.V., Kochergina O.V., Lagutik A.A. *Advances in Applied Physics*, 2021, no. 2(9), pp. 164—171. (in Russ.)
13. Zenevich A.O., Kochergina O.V. *Semiconductors*, 2021, no. 1(26), pp. 30—39. (in Russ.)
14. Gulakov I.R., Zenevich A.O. *Fotopriyemniki kvantovykh sistem* (Photodetectors of Quantum Systems), Minsk, 2012, 276 p. (in Russ.)
15. Asayonak M.A., Zenevich A.O., Kacharhina V.V., Novikau Ya.V., Saroka S.A. *Proceedings of the National Academy of Sciences of Belarus. Physico-Technical Series*, 2020, no. 3(65), pp. 349—356. (in Russ.)

#### **Data on authors**

**Ivan R. Gulakov**

— Dr. Sci., Professor; Belarusian State Academy of Communications, Department of Mathematics and Physics; E-mail: gulakov@bsu.by

<b>Andrey O. Zenevich</b>	—	Dr. Sci., Professor; Belarusian State Academy of Communications; Rector of the Academy; E-mail: a.zenevich@bsac.by
<b>Olga V. Kochergina</b>	—	Belarusian State Academy of Communications, Department of Radio and Information Technologies; Lecturer; E-mail: o.kochergina@bsac.by

Received 23.06.2023; approved after reviewing 08.07.2023; accepted for publication 27.09.2023.

---

# ПРИБОРЫ, СИСТЕМЫ И ИЗДЕЛИЯ МЕДИЦИНСКОГО НАЗНАЧЕНИЯ

## MEDICAL DEVICES, SYSTEMS, AND PRODUCTS

---

УДК 51-76

DOI: 10.17586/0021-3454-2023-66-11-968-981

### СОЗДАНИЕ НАБОРОВ ДАННЫХ КОМПЬЮТЕРНОЙ ТОМОГРАФИИ БРЮШНОЙ АОРТЫ С ПОДАВЛЕНИЕМ КОНТРАСТИРОВАНИЯ ДЛЯ ОБУЧЕНИЯ И ТЕСТИРОВАНИЯ АЛГОРИТМОВ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

М. Р. КОДЕНКО<sup>1,2\*</sup>, А. В. САМОРОДОВ<sup>1</sup>, Н. С. КУЛЬБЕРГ<sup>3</sup>, Р. В. РЕШЕТНИКОВ<sup>2</sup>

<sup>1</sup> Московский государственный технический университет им. Н. Э. Баумана, Москва, Россия  
\*m.r.kodenko@yandex.ru

<sup>2</sup> Научно-практический клинический центр диагностики и телемедицинских технологий  
Департамента здравоохранения города Москвы, Москва, Россия

<sup>3</sup> Федеральный исследовательский центр „Информатика и управление“ РАН,  
Москва, Россия

**Аннотация.** Представлен подход к автоматизированному получению бесконтрастных компьютерных томографических (КТ) изображений, содержащих разметку брюшного отдела аорты, полученную из данных контрастно-усиленной фазы сканирования. Разработан алгоритм подавления контрастного усиления в области брюшного отдела аорты на КТ-изображении. Научная новизна подхода заключается в преобразовании размеченных контрастированных изображений в бесконтрастные с помощью разработанной математической модели, позволяющей выделить и подавить составляющую рентгеновского поглощения контрастного вещества. Тестирование алгоритма проведено на открытом наборе данных, состоящем из 4 КТ-исследований брюшного отдела аорты, баланс классов „аневризма:норма“ — 1:1. Результаты демонстрируют сопоставимость значений рентгеновской плотности в области исследования с литературными данными, а также сходство этой области с окружающей мышечной тканью. Экспертная классификация смешанной выборки, содержащей реальные и генерированные изображения, продемонстрировала реалистичность последних (точность обнаружения искусственных изображений — 35 %, каппа Флейса — 0,12). Полученные изображения предназначены для обучения и тестирования алгоритмов искусственного интеллекта в сфере оппортунистического скрининга аневризмы аорты.

**Ключевые слова:** компьютерная томография, обработка изображений, обучающие наборы данных, искусственный интеллект, синтетическая бесконтрастная фаза

**Благодарности:** работа выполнена в рамках НИР/НИОКР (№ ЕГИСУ: 123031500002-1) в соответствии с Приказом от 21.12.2022 г. № 1196 „Об утверждении государственных заданий, финансовое обеспечение которых осуществляется за счет средств бюджета города Москвы, государственным бюджетным (автономным) учреждениям, подведомственным Департаменту здравоохранения города Москвы, на 2023 год и плановый период 2024 и 2025 годов“; авторы выражают благодарность сотрудникам НПКЦ ДиТ ДЗМ, врачам-рентгенологам И. А. Блохину, А. К. Сморчковой и А. Н. Хоружей за экспертную валидацию КТ-изображений.

**Ссылка для цитирования:** Коденко М. Р., Самородов А. В., Кульберг Н. С., Решетников Р. В. Создание наборов данных компьютерной томографии брюшной аорты с подавлением контрастирования для обучения и тестирования алгоритмов искусственного интеллекта // Изв. вузов. Приборостроение. 2023. Т. 66, № 11. С. 968—981. DOI: 10.17586/0021-3454-2023-66-11-968-981.

**CREATING CONTRAST-SUPPRESSED ABDOMINAL AORTA CT DATASETS  
FOR TRAINING AND TESTING ARTIFICIAL INTELLIGENCE ALGORITHMS**

M. R. Kodenko<sup>1,2\*</sup>, A. V. Samorodov<sup>1</sup>, N. S. Kulberg<sup>3</sup>, R. V. Reshetnikov<sup>2</sup>

<sup>1</sup> Bauman Moscow State Technical University, Moscow, Russia  
m.r.kodenko@yandex.ru

<sup>2</sup> Scientific and Practical Clinical Center for Diagnostics and Telemedicine Technologies  
of the Moscow City Health Department, Moscow, Russia

<sup>3</sup> Federal Research Center "Computer Science and Control" of the RAS, Moscow, Russia

**Abstract.** An approach to the automated acquisition of non-contrast computed tomography (CT) images containing abdominal aortic markings derived from contrast-enhanced phase scanning data is presented. An algorithm for suppressing contrast enhancement in the area of the abdominal aorta on a CT image is developed. The scientific novelty of the approach lies in the conversion of marked contrast images into non-contrast images using a developed mathematical model that allows for isolation and suppression of the component of X-ray absorption of the contrast agent. The algorithm was tested on an open data set consisting of 4 CT studies of the abdominal aorta, the balance of "aneurysm: normal" classes was 1:1. The results demonstrate the comparability of the X-ray density values in the study area with literature data, as well as the similarity of this area with the surrounding muscle tissue. Expert classification of a mixed sample containing real and generated images demonstrates the realism of the latter (accuracy of detection of artificial images - 35%, Fleiss kappa - 0.12). The resulting images are intended for training and testing artificial intelligence algorithms in the field of opportunistic screening of aortic aneurysm.

**Keywords:** computed tomography, image processing, training datasets, artificial intelligence, synthetic non-contrast phase

**Acknowledgments:** The work was carried out within the framework of research and development (EGISU No.: 123031500002-1) in accordance with Order No. 1196 dated December 21, 2022 "On approval of government tasks, the financial support of which is carried out from the budget of the city of Moscow, to state budgetary (autonomous) institutions, subordinate to the Moscow City Health Department, for 2023 and the planning period of 2024 and 2025". The authors express their gratitude to the staff of the Center for Diagnostics and Telemedicine Technologies, Radiologists I. A. Blokhin, A. K. Smorchkova, and A. N. Khoruzhaya for expert validation of CT images.

**For citation:** Kodenko M. R., Samorodov A. V., Kulberg N. S., Reshetnikov R. V. Creating contrast-suppressed abdominal aorta CT datasets for training and testing artificial intelligence algorithms. *Journal of Instrument Engineering*. 2023. Vol. 66, N 11. P. 968—981 (in Russian). DOI: 10.17586/0021-3454-2023-66-11-968-981.

**Введение.** Наличие обучающих наборов данных является обязательным условием разработки и развития технологий машинного обучения (machine learning — ML) [1]. Одна из перспективных и активно развивающихся областей применения ML в сфере лучевой диагностики — автоматизация оппортунистического скрининга [2] патологий брюшного отдела аорты по данным компьютерной томографии (КТ) [3]. Данный вид скрининга предполагает отсутствие контрастного усиления (КУ) в исследовании [4]. Эта особенность является ключевой проблемой при подготовке данных для обучения и тестирования алгоритмов ML, так как сходство рентгеновской плотности между окружающей мышечной тканью и областью „интеса“ (Region of Interest — ROI) [5] существенно осложняет сегментацию последней.

Литературный анализ существующих подходов к созданию размеченных бесконтрастных КТ-изображений брюшного отдела аорты демонстрирует явное смещение в сторону методов искусственной генерации размеченных изображений с помощью нейросетей генеративно-состязательного типа (Generative Adversarial Nets — GAN). Такой подход считается наиболее перспективным, так как позволяет создавать данные, имеющие сходные, но не идентичные первоначальным признакам [6], качественно расширяя исходный набор. Несмотря на то, что число работ, посвященных созданию синтетических бесконтрастных КТ-изображений аорты, весьма ограничено, можно выделить общие недостатки GAN-подхода. Во-первых, для GAN, как и для искусственного интеллекта (ИИ) в целом, характерна зависимость результата от качества и объема обучающих данных [7]. Во-вторых, для GAN-моделей актуальна проблема сходимости и коллапса модели, вызывающих появление одного и того же результата при различных входных данных [8]. Также известен способ

получения бесконтрастных КТ-изображений из КУ-фазы ангиографического исследования с помощью методики двух энергий [9]. Основным ограничением к применению данного способа, при его безусловной диагностической ценности, является низкая доступность метода [10]. Следует также отметить, что создание бесконтрастных изображений не предполагает их автоматическую разметку, для подобных задач также используют ИИ либо привлекают экспертов-рентгенологов, что связано, в свою очередь, с риском возникновения „спутывающих факторов“ [11] либо с дополнительными трудозатратами [12].

В настоящей статье в качестве решения предложен альтернативный подход к преобразованию размеченных контрастированных КТ-изображений в бесконтрастные с сохранением корректной (т.е. выполненной на изображении с КУ) разметки. Разработанное для данных целей программное обеспечение (ПО) не использует машинное обучение и основано на разработанном математическом алгоритме подавления контрастирования [13—15]. Целью настоящего исследования является проверка следующих гипотез:

1) разработанный подход позволяет подавлять контраст-индукционный детерминированный компонент сигнала рентгеновской плотности в области брюшного отдела аорты на КТ-изображениях;

2) разработанный подход позволяет получать КТ-изображение брюшного отдела аорты, статистически значимо не отличающегося от окружающих мышечных тканей по значению рентгеновской плотности.

**Материалы и методы.** Исследование организовано в соответствии с методологией MI-CLAIM [16], регламентирующей порядок клинического использования технологий ИИ в медицине. *Дизайн исследования* — ретроспективный анализ данных КТ-ангиографии (КТА). *Критерии включения*: наличие артериальной фазы сканирования в исследовании; толщина срезов не более 1,5 мм; наличие исследований с диагностированной аневризмой брюшного отдела аорты (код МКБ10 I71 [17]). *Критерии исключения*: наличие областей диссекции (расслоения) сосуда; наличие внутрисосудистых стентов или протезов. *Референсный метод*: в качестве референсных выбраны данные о рентгеновской плотности тканей поясничных мышц для того же исследования, а также литературные данные о плотности крови в аорте (30—45 единиц Хаунсфилда (HU) [18]).

*Подготовка данных.* На подготовительном этапе была проведена разметка данных ангиографического КТ-исследования органов брюшной полости. Под термином „разметка“ в контексте представленной работы понимается маркировка медицинскими экспертами („разметчиками“) пикселов изображения, принадлежащих целевой ROI. Результат разметки — так называемая „маска“ — трехмерный массив, размерность которого соответствует исходным данным, а значение каждого пикселя закодировано бинарно в зависимости от его локализации: принадлежит либо не принадлежит ROI. „Размеченным“ считается изображение, имеющее маску. Целевая ROI — брюшной отдел аорты. Были определены следующие требования к разметчикам: сертификат по специальности „Рентгенология“ и опыт работы не менее трех лет. Разметка данных осуществлялась с помощью ПО Slicer 3D [19] с использованием встроенных инструментов полуавтоматической разметки („row from seed“, „fill between slices“ и др.). Формат NIfTi (Neuroimaging Informatics Technology Initiative) [20] был выбран для обработки, хранения и обмена данными. Полученная маска была дополнительно радиально расширена на область сосудистой стенки и окружающих тканей для корректной работы модели. Расширение ROI выполнено с помощью нерезкого маскирования [21] с радиусом размытия функции Гаусса [22], равным 4 пкс. Экспертный анализ КТ-метрик полученных изображений проводился с помощью ПО Vidar (версия 3.3) [23].

*Генерация искусственных бесконтрастных КТ-изображений.* В основе работы алгоритма обработки данных (рис.1) лежит предложенная ранее модель [15], описывающая кон-

траст-индуцированный компонент поглощения рентгеновского излучения как детерминированный компонент сигнала рентгеновской плотности.




Рис. 1

Общий вид аппроксимирующей функции представляет собой суперпозицию симметричных сигмоид специального вида:

$$F(x) = F_0 - a \cdot \left( \frac{1}{1 + \exp(bx - c)} - \frac{1}{1 + \exp(dx - e)} \right), \quad (1)$$

где  $F_0$  — уровень сигнала вне области сосуда;  $a$  — амплитуда сигнала;  $b, c, d$  и  $e$  определяют положение и наклон боковых сигмоид.

Коэффициенты аппроксимирующей функции вычисляются итеративно методом нелинейных наименьших квадратов (МНК) [24, 25]. Начальные условия для каждой строки (столбца) данных определяются на основании аппроксимируемых данных:

1)  $F_0$  — минимальный уровень сигнала;

2)  $a$  — абсолютная разность между максимальным и минимальным неотрицательным уровнями сигнала;

3)  $c, e$  — индексы начальной и конечной точек сигнала;

4)  $b, d$  равны единице, что соответствует симметричной форме сигнала.

Аппроксимация проводится на каждом изображении в аксиальной проекции отдельно для строк и столбцов ROI. Результаты постстроковой и построчной аппроксимации формируют итоговый сигнал по критерию близости к исходным данным:

$$F_{\text{CAiDC}}(\text{pix}) = \begin{cases} F_i(\text{pix}), & \text{если } |F_i(\text{pix}) - F(\text{pix})| \leq |F_j(\text{pix}) - F(\text{pix})|; \\ F_j(\text{pix}), & \text{если } |F_i(\text{pix}) - F(\text{pix})| > |F_j(\text{pix}) - F(\text{pix})|, \end{cases} \quad (2)$$

где  $F(\text{pix})$  — исходное значение,  $F_i(\text{pix})$  — результат построчной, а  $F_j(\text{pix})$  — постстроковой аппроксимации в пикселе  $\text{pix}$  с координатами  $(i; j)$ .

Для каждого исследования на вход алгоритма было передано по три набора данных в формате NIfTi: КТ-исследование и две бинарные маски разметки — исходная и расширенная. Далее проводилось извлечение ROI из исходных данных посредством специального пересечения с масками. Бинарная маска имеет размерность исходного изображения и структуру, определяющую целевые пиксели ROI значением „1“, остальные — значением „0“. Проводится инверсия значений маски, замена единичных значений на „Not-a-Number“ (NaN) и последующее сложение с исходным изображением. Результатом операции является обращение в NaN всех значений на исходном изображении вне ROI. Этот подход применялся для оптимизации времени вычислений данных.

Полученный трехмерный массив посрезово обрабатывался в цикле. Методом аппроксимации с помощью нелинейных наименьших квадратов проводилось извлечение контраст-индуцированного детерминированного компонента сигнала рентгеновской плотности. Извлеченный компонент затем был попиксельно вычен из исходных данных с учетом корректирующего фактора.

Расчет корректирующих факторов основан на необходимости соблюдения двух условий: отсутствие объектов избыточной яркости в ROI (кальцинаты, кости) и соблюдение требований к обеспечению сходства между ROI и окружающей мышечной тканью (для бесконтрастного КТ-исследования плотность крови 30—45 HU [18], плотность мышечной ткани 34—50 HU [26]). Применение корректирующих факторов является ограничением работы, возможные эффекты и их влияние на конечные результаты подробно рассмотрены далее.

Для маскирования ярких объектов применяется поиск соответствующих пикселов и снижение их яркости. Первый корректирующий фактор (КФ1) рассчитывается индивидуально для каждого среза как минимальное значение рентгеновской плотности в просвете сосуда. При обнаружении объектов, рентгеновская плотность которых превышает КФ1, значение соответствующих пикселов заменяется на значение среднего уровня поглощения мягких тканей на данном изображении. Это значение является вторым корректирующим фактором (КФ2) и рассчитывается по области строгой дизъюнкции исходной и расширенной масок, т.е. по области, содержащей только окружающие ткани (вне просвета сосуда). КФ2 равен среднеарифметическому значению пикселов в диапазоне интенсивностей от 0 до КФ1.

КФ2 также используется на финальном этапе обработки данных для обеспечения сходства между ROI и окружающей мышечной тканью. Результат аппроксимации данных попик-

сельно вычитается из исходных данных в пределах маски. Таким образом, в ROI остается сигнал, соответствующий рентгеновскому поглощению крови в бесконтрастной фазе исследования. Однако важно учитывать, что даже в ранней артериальной фазе может наблюдаться статистически значимое повышение рентгеновской плотности мышечной ткани [27]. По этой причине проводится проверка сопоставимости полученных данных области просвета сосуда и величины КФ2. В случае если средний уровень полученного сигнала ниже вычисленного КФ2, попиксельно проводится увеличение результата на величину  $\Delta$ :

$$\Delta = \text{КФ2} - \text{mean}(F), \quad (3)$$

где  $\text{mean}$  — средняя ордината полученного сигнала в ROI ( $F$ ).

*Анализ результатов.* Полученные данные были обработаны с помощью ПО R (версия 4.1.1) [28]. Уровень статистической значимости для принятия гипотез был принят равным 0,05.

*Проверка первой гипотезы.* Для оценки эффективности подавления контраст-индуцированного детерминированного компонента (тренда) был использован сравнительный статистический анализ данных до и после преобразования. С помощью теста WAVK [29], в котором нулевая гипотеза об отсутствии тренда проверялась против гипотезы о наличии немонотонного тренда, были проанализированы исходные и обработанные данные. Тип тренда (немонотонный) был определен на основании визуального анализа данных КТ. На рис. 2, *a*, *б* показана рентгеновская плотность ( $D$ ) в бесконтрастной (*a*) и контрастно усиленной (*б*) фазах КТ-сканирования; форма аппроксимирующей функции для извлечения тренда из КУ-сигнала приведена на рис. 2, *в*.




Рис. 2

Результат подавления КУ в ROI (до применения коррекции с помощью КФ2) был проанализирован с помощью 95%-ного доверительного интервала (confidence interval — CI) для разности средних значений двух выборок [30]:

$$\text{CI} = |\text{mean}(F) - \text{mean}(F_0)| \pm z \sqrt{\text{sd}(F)^2 + \text{sd}(F_0)^2}, \quad (4)$$

где  $\text{sd}$  — среднеквадратическое отклонение для полученных ( $F$ ) и референсных ( $F_0$ ) данных,  $z$  — табличное значение для заданного уровня значимости (1,96 для уровня значимости 0,05).

В качестве референсных данных были использованы результаты исследования [18], согласно которому значения рентгеновской плотности для нетромбированной крови составляют  $D = 30 \dots 45 \text{ HU}$ .

*Проверка второй гипотезы.* Для оценки результатов по критерию сходства плотности между ROI и окружающей мышечной тканью с помощью статистического теста Манна —

Уитни [31] были сопоставлены распределения рентгеновской плотности в ROI и в параспинальной мышечной ткани. Для этого на каждом срезе расширенной маски были извлечены данные вне ROI, плотность которых находится в диапазоне от 30 до КФ1, и сопоставлены с данными внутри ROI после обработки.

Дополнительно был проведен экспертный анализ изображений врачами-рентгенологами. Данный подход, несмотря на субъективность, позволяет выявить наличие в результатах специфических паттернов, которые указывают на синтетический характер изображения. Для экспертной оценки был сформирован набор данных, содержащий 14 изображений в формате DICOM (ГОСТ Р ИСО 12052-2009), баланс классов „истинное:сгенерированное“ изображение составил 1:1, что соответствовало балансу классов исходной выборки. Изображения для экспертного анализа были предварительно обрезаны с помощью инструмента „сгор“ в программе Slicer 3D, так чтобы в поле зрения не попадали объекты с КУ вне ROI (магистральные артерии, поджелудочная железа). Число изображений было получено после применения к выборке критериев исключения: наличие вне ROI КУ-объектов, которые нельзя удалить из поля обзора. В качестве изображений „истинного“ класса выбрано 7 изображений бесконтрастных серий соответствующих КТ-исследований. При отсутствии таковых в исследовании выбиралась серия, содержащая минимальный уровень контрастирования в ROI (венозная или отсроченная серия сканирования). В экспертизе приняли участие 3 врача-рентгенолога с опытом работы от 1 года до 5 лет. Участники были „заслеплены“ относительно результатов друг друга и данных о балансе классов выборки. Порядок изображений был уникальным для каждого эксперта. Просмотр и оценивание осуществлялись с помощью ПО VidaR без ограничений по используемым инструментам: изменение диапазона яркости, изменение плотности объекта и др. Данные были независимо оценены и классифицированы экспертами бинарно: „настоящее“ (0) либо „искусственное“ (1) изображение брюшного отдела аорты. По этим данным были рассчитаны метрики чувствительности (Se), специфичности (Sp) и точности (Ac) экспертных оценок в отношении корректной классификации изображений:

$$Se = \frac{TP}{TP+FN}; \quad (5)$$

$$Sp = \frac{TN}{FP+TN}; \quad (6)$$

$$Ac = \frac{(TP+TN)}{(TP+TN+FP+FN)}, \quad (7)$$

где TP — истинно положительный, TN — истинно отрицательный, FP — ложноположительный и FN — ложноотрицательный результаты классификации.

Кроме того, была рассчитана мера согласованности разметчиков — каппа Флейса с помощью функции R kappam.fleiss пакета irr [32, 33].

**Результаты.** Набор данных содержал результаты 4 КТА-исследований, общее число изображений — 594, медианное число срезов в исследовании 177 (размах составил 128—178). Баланс классов „аневризма:норма“ составил 1:1. Толщина срезов в исследовании варьировалась от 1 до 3 мм. Все исследования содержали артериальную фазу сканирования, однако ни в одном исследовании не было обнаружено бесконтрастной фазы сканирования.

Использованный способ оптимизации обработки данных за счет удаления данных вне маски с помощью NaN позволил оптимизировать вычисления по времени: время обработки на процессоре Intel Core i7 (ОЗУ 16 Гб) с использованием оптимизации уменьшилось в 12 раз (180 мс против 15 мс на обработку одного аксиального среза размером 512×512 пкс).

На рис. 3 представлен результат применения КФ1 для данных, содержащих кальцинаты в стенке аорты (кальцинат показан стрелкой). Подавление кальцината на исходном изображении (рис. 3, а) не привело к искажению его формы и локализации в итоговом изображении (рис. 3, б).




Рис. 3

*Проверка первой гипотезы исследования продемонстрировала статистически достоверное отсутствие тренда ( $p\text{-value} > 0,05$ ) в сигнале после подавления КУ при его наличии в исходных данных для всех исследований (рис. 4; штриховая линия показывает уровень значимости 0,05). Срезы, для которых в синтетической бесконтрастной фазе был обнаружен тренд (левый боксплот на рис. 4, значения ниже уровня  $p\text{-value} 0,05$ ), содержали фрагменты отхождения магистральных артерий, поэтому не были учтены при интерпретации результатов. Результаты расчета 95%-ного CI по формуле (4) для данных после подавления КУ и литературных данных о рентгеновской плотности аорты в бесконтрастной фазе демонстрируют наличие нулевого значения в интервалах для всех КТ-исследований (рис. 5), что подтверждает отсутствие статистически значимых различий между литературными и рассчитанными значениями рентгеновской плотности пикселов ROI.*




Рис. 4




Рис. 5

*Результат проверки второй гипотезы исследования демонстрирует отсутствие статистически значимых различий ( $p\text{-value} > 0,05$ ) в данных ROI после коррекции и в области параспинальной мышечной ткани. Визуально это сходство выражается в эффекте „неотделимости“ области ROI от окружающей мышечной ткани (рис. 6, посередине), характерном для реальных бесконтрастных изображений.*

Показатели чувствительности и специфичности экспертов оценок при классификации изображений составляют 40—70 % и 28—71 % соответственно, точность — всего 23—35 %. При этом наблюдался низкий уровень согласованности экспертов (каппа Флейса 0,12). Детализация результатов обработки представлена на рис. 7: *a* — реальные, *б* — искусственные изображения; ответы экспертов отмечены квадратами: серый — ложный ответ, белый — верный; случаи полного согласия экспертов отмечены прямоугольниками. Доля изображений,

единогласно корректно классифицированных экспертами, составила 20 %; два получены с использованием предложенного алгоритма, одно — исходное.



Рис. 6




Рис. 7

**Обсуждение результатов.** Предложен способ подавления контрастного усиления на КТ-изображениях брюшного отдела аорты. Разработанный алгоритм позволяет получать изображения ROI:

- соответствующие по своим параметрам реальной бесконтрастной фазе исследования (95 % CI для разницы средних значений пересекают нулевое значение для всех 4 КТ-исследований);
- не отличающиеся от прилежащей мышечной ткани по значению рентгеновской плотности и структуре ( $p\text{-value} > 0,05$ );
- содержащие разметку ROI, выполненную в соответствии с золотым стандартом диагностики аневризм [34], на изображениях с КУ (пример получения размеченного бесконтрастного изображения — см. рис. 6).

Полученные данные имеют высокий уровень сходства с естественным изображением не только по количественным, но и по качественным характеристикам, что подтверждается результатами экспертной оценки (низкая точность выявления синтетических изображений — до 35 % при низкой согласованности экспертов, каппа Флейса 0,12).

Главное отличие предложенного подхода от существующих решений заключается в том, что данный подход не использует методы синтетической генерации и машинного обучения. Разработанный алгоритм основан на математическом анализе исходных данных, используемая модель позволяет выделить детерминированный компонент сигнала рентгеновской плотности, что дает возможность получать исходные данные бесконтрастной фазы вместо их синтетической генерации. Таким образом, создание бесконтрастных изображений происходит автоматически и лишено характерных для GAN-подхода недостатков [6, 35]:

- во-первых, отсутствует зависимость качества работы модели от объема обучающих наборов данных, так как модель не требует обучения;

— во-вторых, отсутствует риск внесения систематической ошибки при разметке данных, связанный с вариабельностью ручной разметки ROI на бесконтрастном изображении: разметка исходного изображения проводится при наличии КУ;

— наконец, отсутствуют трудности получения изображений с редкими признаками, так как для получения одного обработанного изображения не требуется библиотека изображений с целевым объектом.

Главным преимуществом предложенного метода относительно использования двухэнергетической КТ является подавление КУ только в выбранной области, тогда как указанный метод (равно как и субстракция изображений [36]) приводит к подавлению всех объектов, не содержащих контрастное вещество. Кроме того, данные изображения не содержат разметку ROI, в отличие от полученных предложенным методом.

**Ограничения.** К ограничениям работы следует отнести применение корректирующих факторов (КФ1 и КФ2) и необходимость обрезки обработанных изображений.

Применение комбинации КФ1 и КФ2 для маскирования кальцинатов проводится с целью корректной аппроксимации данных. При этом данные области просто исключаются из анализа, поскольку кальцинаты не участвуют в измерении просвета сосуда, которое проводится при диагностике аневризм [34]. Применение КФ2 на финальном этапе обработки изображений связано с риском внесения систематической погрешности в данные, однако адаптивный расчет его значения для каждого изображения снижает данный риск. Отсутствие синтетических паттернов, связанных с применением указанной коррекции, подтверждается результатом экспертной оценки изображений (см. рис. 7).

Обрезка изображений, связанная с локальным (в пределах маски) подавлением КУ, ограничивает объем данных участками вне отхождения магистральных артерий и прилежания активно контрастируемых паренхиматозных органов (например, поджелудочная железа). Влияние ограничения следует рассматривать с точки зрения целевой функции генерируемых данных. Аневризма аорты — диагноз, определяемый по диаметру просвета сосуда, который не измеряют на участках отхождения артерий [34]. Тем не менее расширение области подавления КУ на изображении является одним из направлений дальнейшей работы.

Авторы вынуждены отметить высокую вариабельность результатов статистической обработки данных. Во-первых, представленные результаты сопоставления параспинальной мышечной ткани методом Манна — Уитни могут не удовлетворять критерию независимости выборок по причине коррекции результата на величину, рассчитанную по референсной области. В дальнейшем предполагается расширить объем референсных данных для получения более надежных и воспроизводимых результатов. Во-вторых, может возникнуть неоднозначность при сопоставлении данных после подавления КУ и литературных значений плотности аорты. Дополнительно был проведен внутригрупповой сравнительный анализ для исследований с подавлением КУ методом Крускала — Уоллеса [37]: результаты теста демонстрируют статистически значимые различия для всех четырех исследований ( $p\text{-value} < 0.001$ ). Это свидетельствует о необходимости учета параметров сканирования и сопоставления данных между сериями одного и того же КТ-исследования, что было невозможно в рамках настоящей работы вследствие неполноты данных в открытом доступе.

Таким образом, представленные в статье результаты, хотя и проанализированы с использованием формально корректной методологии, носят предварительный характер. Основным направлением дальнейших исследований является валидация работы алгоритма на репрезентативном по наличию необходимых фаз сканирования наборе данных, подготовка которого ведется авторами в настоящее время.

**Заключение.** Представлен алгоритм для получения бесконтрастных КТ-изображений брюшного отдела аорты, содержащих разметку области ROI, полученную на контрастно-усиленных изображениях. Предложенный алгоритм предназначен для повышения качества и

доступности обучающих данных для алгоритмов ИИ оппортунистического скрининга аневризм брюшной аорты.

**Вклад авторов.** М. Р. Коденко — концепция и дизайн исследования, получение и анализ данных, подготовка и редактирование рукописи; А. В. Самородов, Н. С. Кульберг и Р. В. Решетников — экспертная оценка методологии исследования; Р. В. Решетников — администрирование проекта и редактирование рукописи.

#### СПИСОК ЛИТЕРАТУРЫ

1. Koshino K., Werner R. A., Pomper M. G. et al. Narrative review of generative adversarial networks in medical and molecular imaging // Ann. Transl. Med. 2021. Vol. 9, N 9. P. 821—821.
2. Engelke K., Chaudry O., Bartenschlager S. Opportunistic Screening Techniques for Analysis of CT Scans // Curr Osteoporos Rep. Springer, 2023. Vol. 21, N 1. P. 65—76.
3. Kodenko M. R., Vasilev Y. A., Vladzmyrskyy A. V. et al. Diagnostic Accuracy of AI for Opportunistic Screening of Abdominal Aortic Aneurysm in CT: A Systematic Review and Narrative Synthesis // Diagnostics. 2022. Vol. 12, N 12. P. 3197.
4. Шаблоны протоколов описания исследований по специальности «Рентгенография» магнитно-резонансная томография // НПКЦ ДиТ ДЗМ: сайт. Москва, 2016 [Электронный ресурс]: <[https://trauma.ru/content/articles/detail.php?ELEMENT\\_ID=45874](https://trauma.ru/content/articles/detail.php?ELEMENT_ID=45874)>, 25.03.2023.
5. Corson N., Sensakovic W. F., Straus C. et al. Characterization of mesothelioma and tissues present in contrast-enhanced thoracic CT scans // Med. Phys. American Association of Physicists in Medicine. 2011. Vol. 38, N 2. P. 942. DOI: 10.1111/1.3537610
6. Goodfellow I. et al. Generative Adversarial Networks // Commun ACM. Association for Computing Machinery. 2014. Vol. 63, N 11. P. 139—144. DOI: 10.48550/arXiv.1406.2661.
7. Litjens G. et al. A Survey on Deep Learning in Medical Image Analysis // Med. Image Anal. Elsevier B.V., 2017. Vol. 42. P. 60—88. DOI: 10.1016/j.media.2017.07.005.
8. Kodali N. et al. On Convergence and Stability of GANs. 2017. DOI: 10.48550/arXiv.1705.07215.
9. Петровичев В. С., Неклюдова М. В., Синицын В. Е., Никитин И. Г. Двухэнергетическая компьютерная томография рака головы и шеи // Digital Diagnostics. 2021. Т. 2, № 3. С. 343—355. DOI: 10.17816/DD62572.
10. Toshav A. Economics of Dual-Energy CT: Workflow, Costs, and Benefits // Seminars in Ultrasound, CT and MRI. 2022. Vol. 43, N 4. С. 352—354. DOI: 10.1053/j.sult.2022.06.010.
11. Zhao Q., Adeli E., Pohl K. M. Training confounder-free deep learning models for medical applications // Nature Communications. 2020. Vol. 11, N 1. P. 1—9. DOI: 10.1038/s41467-020-19784-9.
12. Starmans M. P. A. et al. Radiomics // Handbook of Medical Image Computing and Computer Assisted Intervention. Elsevier, 2019. P. 429—456.
13. Свид. о гос. рег. программы № 2023661089 РФ. Программа для извлечения и анализа детерминированного компонента сигнала рентгеновской плотности КТ-ангиографического исследования аорты / М. Р. Коденко, Ю. А. Васильев. Опубл. 29.05.2023. Бюл. № 6.
14. Свид. о гос. рег. программы № 2023661090 РФ. Программа для подавления контрастирования аорты на КТ-ангиографических изображениях / М. Р. Коденко, Ю. А. Васильев. Опубл. 29.05.2023. Бюл. № 6.
15. Коденко М. Р., Кульберг Н. С., Самородов А. В. Анализ высокоплотностного компонента содержимого брюшной аорты при КТ-ангиографии // Сб. тез. XXX Междунар. конф. „Математика. Компьютер. Образование“ 2023 [Электронный ресурс]: <<http://www.mce.su/rus/archive/abstracts/mce30/sect288919/doc417793/>>, 25.03.2023.
16. Norgeot B. et al. Minimum information about clinical artificial intelligence modeling: the MI-CLAIM checklist // Nature Medicine. 2020. Vol. 26, N 9. P. 1320—1324. DOI: 10.1038/s41591-020-1041-y.
17. МКБ 10 — Аневризма и расслоение аорты (I71) // МКБ 10 - Международная классификация болезней 10-го пересмотра [Электронный ресурс]: <<https://mkb-10.com/index.php?pid=8344>>, 05.04.2023.

18. Robinson J. D. et al. Imaging of blunt abdominal solid organ trauma // Seminars in Roentgenology. 2016. Vol. 51, N 3. P. 215—229. DOI: 10.1053/j.ro.2015.12.003.
19. 3D Slicer image computing platform // 3D Slicer USA [Электронный ресурс]: <<https://www.slicer.org/>>, 05.03.2022.
20. Knipe H., Moore C. NIfTI (file format) // Radiopaedia.org. 2019 [Электронный ресурс]: <<https://radiopaedia.org/articles/72562>>, 05.03.2022.
21. Haralick R., Shapiro L. Computer and Robot Vision. Addison-Wesley Publ. Company, 1992.
22. Uchida S. Image processing and recognition for biological images. Dev Growth Differ // Wiley Online Library. 2013. Vol. 55, N 4. P. 523—549. DOI: 10.1111/dgd.12054.
23. Vidar Dicom Viewer // Vidar [Электронный ресурс]: <<https://povidar.ru/dicom-viewer/v3/versions.html>>, 05.03.2022.
24. Kelley C. T. Iterative methods for optimization. Society for Industrial and Applied Mathematics, 1999.
25. Emmert-Streib F., Moutari S., Dehmer M. Mathematical Foundations of Data Science Using R. Berlin: De Gruyter, 2020. P. 1—414.
26. Barnard R. et al. Machine Learning for Automatic Paraspinous Muscle Area and Attenuation Measures on Low-Dose Chest CT Scans // Acad. Radiol. Elsevier. 2019. Vol. 26, N 12. P. 1686—1694. DOI: 10.1016/j.acra.2019.06.017.
27. Boutin R.D. et al. Influence of IV Contrast Administration on CT Measures of Muscle and Bone Attenuation: Implications for Sarcopenia and Osteoporosis Evaluation // Amer. Roentgen Ray Society. 2016. Vol. 207, N 5. P. 1046—1054. DOI: 10.2214/AJR.16.16387.
28. RStudio Desktop - Posit // RStudio [Электронный ресурс]: <<https://posit.co/download/rstudio-desktop/>>, 05.03.2022.
29. wavk.test function // RDocumentation [Электронный ресурс]: <<https://www.rdocumentation.org/packages/funr/versions/6.1/topics/wavk.test>>, 05.03.2022.
30. Penn State Pulse, 21st Birthday, January 2001 // Pennsylvania State University [Электронный ресурс]: <<http://www.sa.psu.edu/sara/alphapulse.shtml>>, 13.06.2023.
31. Mann H. B., Whitney D. R. On a Test of Whether one of Two Random Variables is Stochastically Larger than the Other // The Annals of Mathematical Statistics. 1947. Vol. 18, N 1. P. 50—60.
32. Fleiss J. L. Measuring nominal scale agreement among many raters // Psychological Bulletin. 1971. Vol. 76, N 5. P. 378.
33. Fleiss J. L., Levin B., Paik M. C. Statistical methods for rates and proportions. N.Y.: Wiley, 1981. Т. 1981218.
34. Erbel R. et al. 2014 ESC Guidelines on the diagnosis and treatment of aortic diseases: Document covering acute and chronic aortic diseases of the thoracic and abdominal aorta of the adult. The Task Force for the Diagnosis and Treatment of Aortic Diseases of the European Society of Cardiology (ESC) // Eur. Heart Journal. 2014. Vol. 35, N 41. P. 2873—2926.
35. Chen Y. et al. Generative Adversarial Networks in Medical Image augmentation: A review // Comput Biol Med. 2022. Vol. 144. DOI: 10.1016/j.combiomed.2022.105382.
36. Meijer F. J. A. et al. Ultra-high-resolution subtraction CT angiography in the follow-up of treated intracranial aneurysms // Insights Imaging. 2019. Vol. 10, N 1. DOI: 10.1186/s13244-019-0685-y.
37. Kruskal W. H., Wallis W. A. Use of Ranks in One-Criterion Variance Analysis // J. Amer. Stat Assoc. 1952. Vol. 47, N 260. P. 583—621.

***Сведения об авторах*****Мария Романовна Коденко**

— аспирант; МГТУ им. Н. Э.Баумана, кафедра биомедицинских технических систем; Научно-практический клинический центр диагностики и телемедицинских технологий Департамента здравоохранения города Москвы, отдел научных медицинских исследований; мл. научный сотрудник; E-mail: m.r.kodenko@yandex.ru

**Андрей Владимирович Самородов**

— канд. техн. наук, доцент; МГТУ им. Н. Э. Баумана, кафедра биомедицинских технических систем; заведующий кафедрой; E-mail: avs@bmstu.ru

- Николай Сергеевич Кульберг** — канд. физ-мат. наук; ФИЦ „Информатика и управление“ РАН, отдел № 41; ст. научный сотрудник; E-mail: kulberg@yandex.ru
- Роман Владимирович Решетников** — канд. физ-мат. наук; Научно-практический клинический центр диагностики и телемедицинских технологий Департамента здравоохранения города Москвы, отдел научных медицинских исследований; руководитель отдела; E-mail: reshetnikov@fbb.msu.ru

Поступила в редакцию 29.06.2023; одобрена после рецензирования 14.07.2023; принята к публикации 27.09.2023.

## REFERENCES

1. Koshino K., Werner R.A., Pomper M.G. et al. *Ann. Transl. Med.*, 2021, no. 9(9), pp. 821–821.
2. Engelke K., Chaudry O., Bartenschlager S. *Curr. Osteoporos Rep.*, Springer, 2023, no. 1(21), pp. 65–76.
3. Kodenko M.R., Vasilev Y.A., Vladzymyrskyy A.V. et al. *Multidisciplinary Digital Publishing Institute*, 2022, no. 12(12), pp. 3197.
4. [https://trauma.ru/content/articles/detail.php?ELEMENT\\_ID=45874](https://trauma.ru/content/articles/detail.php?ELEMENT_ID=45874). (in Russ.)
5. Corson N., Sensakovic W.F., Straus C. et al. *Med Phys. American Association of Physicists in Medicine*, 2011, no. 2(38), pp. 942, DOI: 10.11118/1.3537610.
6. Goodfellow I. et al. *Commun. ACM. Association for Computing Machinery*, 2014, no. 11(63), pp. 139–144, DOI:10.48550/arXiv.1406.2661.
7. Litjens G. et al. *Med. Image Anal.*, Elsevier B.V., 2017, vol. 42, pp. 60–88, DOI: 10.1016/j.media.2017.07.005.
8. Kodali N. et al. *On Convergence and Stability of GANs*, 2017, DOI: 10.48550/arXiv.1705.07215.
9. Petrovichev V.S., Neklyudova M.V., Sinitsyn V.E., Nikitin I.G. *Digital Diagnostics*, 2021, no. 3(2), pp. 343–355, DOI: 10.17816/DD62572. (in Russ.)
10. Toshav A. *Seminars in Ultrasound, CT and MRI*, WB Saunders, 2022, no. 4 (43), pp. 352–354, DOI: 10.1053/j.sult.2022.06.010.
11. Zhao Q., Adeli E., Pohl K.M. *Nature Communications*, 2020, no. 1(11), pp. 1–9, DOI: 10.1038/s41467-020-19784-9.
12. Starmans M.P.A. et al. *Handbook of Medical Image Computing and Computer Assisted Intervention*, Elsevier, 2019, pp. 429–456.
13. Certificate on the state registration of the computer programs 2023661089, *Programma dlya izvlecheniya i analiza determinirovannogo komponenta signala rentgenovskoy plotnosti KT-angiograficheskogo issledovaniya aorty* (Program for Extracting and Analyzing the Deterministic Component of the X-ray Density Signal of a CT Angiographic Study of the Aorta), M.R. Kodenko, Yu.A. Vasiliev, Priority 19.05.2023, Published 29.05.2023, Bulletin 6. (in Russ.)
14. Certificate on the state registration of the computer programs 2023661090, *Programma dlya podavleniya kontrastirovaniya aorty na KT-angiograficheskikh izobrazheniyakh* (Program for Suppressing Contrast Enhancement of the Aorta on CT Angiographic Images), M.R. Kodenko, Yu.A. Vasiliev, Priority 19.05.2023, Published 29.05.2023, Bulletin 6.
15. Kodenko M.R., Kul'berg N.S., Samorodov A.V. *Matematika. Komp'yuter. Obrazovaniye 2023* (Mathematics. Computer. Education 2023), Collection of abstracts of the XXX Intern. Conf., <http://www.mce.su/rus/archive/abstracts/mce30/sect288919/doc417793/>. (in Russ.)
16. Norgeot B. et al. *Nature medicine*, 2020, no. 9(26), pp. 1320–1324, DOI: 10.1038/s41591-020-1041-y.
17. <https://mkb-10.com/index.php?pid=8344>. (in Russ.)
18. Robinson J. D. et al. *Seminars in roentgenology*, WB Saunders, 2016, no. 3(51), pp. 215–229, DOI: 10.1053/j.ro.2015.12.003.
19. *3D Slicer image computing platform*, <https://www.slicer.org/>.
20. Knipe H., Moore C. *Radiopaedia.org*, 2019, <https://radiopaedia.org/articles/72562>.
21. Haralick R. and Shapiro L. *Computer and Robot Vision*, Addison-Wesley Publishing Company, 1992.
22. Uchida S. *Wiley Online Library*, 2013, no. 4(55), pp. 523–549, doi: 10.1111/dgd.12054.
23. *Vidar Dicom Viewer*, <https://povidar.ru/dicom-viewer/v3/versions.html>.
24. Kelley C.T. *Iterative methods for optimization*, Society for Industrial and Applied Mathematics, 1999.
25. Emmert-Streib F., Moutari S., Dehmer M. *Mathematical Foundations of Data Science Using R*, De Gruyter, 2020, 414 p.
26. Barnard R. et al. *Acad. Radiol.*, 2019, no. 12(26), pp. 1686–1694, DOI: 10.1016/j.acra.2019.06.017.
27. Boutin R.D. et al. *American Roentgen Ray Society*, 2016, no. 5(207), pp. 1046–1054, DOI: 10.2214/AJR.16.16387.
28. *RStudio Desktop – Posit*, <https://posit.co/download/rstudio-desktop/>.
29. *RDocumentation*, <https://www.rdocumentation.org/packages/funtimes/versions/6.1/topics/wavk.test>.
30. *Penn State Pulse*, 21st Birthday, January 2001, Pennsylvania State University, <http://www.sa.psu.edu/sara/alphapulse.shtml>.
31. Mann H.B., Whitney D.R. *The Annals of Mathematical Statistics*, Institute of Mathematical Statistics, 1947, no. 1(18), pp. 50–60.
32. Fleiss J.L. *Psychological bulletin*, 1971, no. 5(76), pp. 378.
33. Fleiss J.L., Levin B., Paik M.C. *Statistical methods for rates and proportions*, NY, Wiley, 1981, vol. 1981218.
34. Erbel R. et al. *Eur. Heart. J.*, 2014, no. 41(35), pp. 2873–2926.
35. Chen Y. et al. *Comput. Biol. Med.*, 2022, vol. 144, DOI: 10.1016/j.combiomed.2022.105382.
36. Meijer F.J.A. et al. *Insights Imaging*, 2019, no. 1(10), DOI: 10.1186/s13244-019-0685-y.
37. Kruskal W.H., Wallis W.A. *J. Am. Stat. Assoc.*, 1952, no. 260(47), pp. 583–621.

**Data on authors**

- Maria R. Kodenko** — Post-Grauate Student; Bauman Moscow State Technical University, Department of Biomedical Technical Systems; Center for Diagnostics and Telemedicine Technologies, Department of Medical Research; Junior Researcher; E-mail: m.r.kodenko@yandex.ru
- Andrey V. Samorodov** — PhD, Associate Professor; Bauman Moscow State Technical University, Department of Biomedical Technical Systems; Head of the Department; E-mail: avs@bmstu.ru
- Nicholay S. Kulberg** — PhD; Federal Research Center "Computer Science and Control" of the RAS, Department 41; Senior Researcher; E-mail: kulberg@yandex.ru
- Roman V. Reshetnikov** — PhD; Center for Diagnostics and Telemedicine Technologies, Department of Medical Research; Head of the Department; E-mail: reshetnikov@fbb.msu.ru

Received 29.06.2023; approved after reviewing 14.07.2023; accepted for publication 27.09.2023.

---

# ПРИБОРЫ И МЕТОДЫ КОНТРОЛЯ И ДИАГНОСТИКИ МАТЕРИАЛОВ, ИЗДЕЛИЙ, ВЕЩЕСТВ И ПРИРОДНОЙ СРЕДЫ

## INSTRUMENTS AND METHODS FOR MONITORING AND DIAGNOSING MATERIALS, PRODUCTS, SUBSTANCES AND THE NATURAL ENVIRONMENT

---

УДК 678, 66.081  
DOI: 10.17586/0021-3454-2023-66-11-982-988

### ОЦЕНКА ПРОЧНОСТИ ЭЛАСТОМЕРНЫХ МЕМБРАН КОНТРОЛЯ ДАВЛЕНИЯ

В. Л. ПОЛОНСКИЙ\*, Е. А. ТАРАСЕНКО, Г. В. ИВАНОВА

Санкт-Петербургский политехнический университет Петра Великого, Санкт-Петербург, Россия

\* [vladimir.polonsky@outlook.com](mailto:vladimir.polonsky@outlook.com)

**Аннотация.** Рассматривается деформация резиновой мембраны толщиной 3 мм под давлением, создаваемым рабочей жидкостью. Мембрана установлена внутри цилиндра и подпирается поршнем. При опускании поршня мембрана перемещается вместе с ним и давление рабочей жидкости деформирует мембрану, растягивая резину по краям поршня. Представлено решение задачи по определению разрушающих напряжений, особенно в области, близкой к креплению мембранны, где происходит основной прогиб резины, ее выворачивание на другую сторону. Приведены расчет и анализ полученных результатов области в углах мембранны по краям поршня, где резина под давлением растягивается. Задача решается как статическая в осесимметричной постановке без учета трения с использованием программы ABAQUS. Рассматривается самый опасный вариант при нулевом трении между резиной и металлом, причем резина рассматривается как нелинейно-упругий слабосжимаемый материал. Проанализированы результаты численных расчетов по критерию прочности на основе стандартных показателей резины: предела прочности и удлинения при разрыве. Представлен вывод о работоспособности мембранны по критерию прочности.

**Ключевые слова:** эластомерный материал, резина, мембрана, нелинейная упругость, прочность, напряжение по Мизесу

**Ссылка для цитирования:** Полонский В. Л., Тарасенко Е. А., Иванова Г. В. Оценка прочности эластомерных мембранны контроля давления // Изв. вузов. Приборостроение. 2023. Т. 66, № 11. С. 982—988. DOI: 10.17586/0021-3454-2023-66-11-982-988.

### EVALUATION OF THE STRENGTH OF ELASTOMERIC MEMBRANES OF PRESSURE CONTROL DEVICES

V. L. Polonsky\*, E. A. Tarasenko, G. V. Ivanova

Peter the Great St. Petersburg Polytechnic University, St. Petersburg, Russia  
\* [vladimir.polonsky@outlook.com](mailto:vladimir.polonsky@outlook.com)

**Abstract.** Deformation of a 3 mm thick rubber membrane under pressure created by working fluid is considered. The membrane is installed inside a cylinder and supported by a piston. When the piston is lowered, the membrane moves with it and the pressure of the working fluid deforms the membrane, stretching the rubber along the edges of the piston. A solution to the problem of determining the breaking stresses is presented, with special attention being paid to the area close to the membrane fastening, where the main deflection of the rubber and its inversion to the other side occur. Calculation and analysis of the results obtained of the area in the corners of the membrane along the edges of the piston, where the rubber is stretched under pressure, are performed. The problem is solved as a static one in an axisymmetric formulation without taking into account friction using the ABAQUS program. The most dangerous option is considered with zero friction between rubber and metal, and rubber is considered as a nonlinearly elastic, weakly compressible material. The results of numerical calculations on the strength criterion based on standard rubber indicators: tensile strength and elongation at break are analyzed. A conclusion is presented about the performance of the membrane according to the strength criterion.

**Keywords:** elastomeric material, rubber, membrane, nonlinear elasticity, strength, von Mises stresses

**For citation:** Polonsky V. L., Tarasenko E. A., Ivanova G. V. Evaluation of the strength of elastomeric membranes of pressure control devices. *Journal of Instrument Engineering*. 2023. Vol. 66, N 11. P. 982—988 (in Russian). DOI: 10.17586/0021-3454-2023-66-11-982-966.

В манометрических приборах в качестве упругого элемента применяется мембрана, представляющая собой пластину, которая под действием давления подвергается значительным упругим прогибам. Мембранны используют как чувствительные элементы в приборах или как разделители двух сред, уплотнители при передаче перемещений из области давления или вакуума [1].

Для изготовления мембран широко применяются эластомерные материалы, обладающие нелинейными свойствами. Изделия из этих материалов могут испытывать деформации без разрушения [2—7].

Непрерывно возрастающие требования к резиновым мембранам, которые используются в установках с повышенными нагрузками и давлением, а также испытывающих химико-физические воздействия, являются объектами конструкторских и технологических расчетов [8].

В настоящей статье рассматривается мембрана толщиной 3 мм, недеформированная форма которой показана на рис. 1. Мембрана установлена внутри цилиндра и снизу подперта поршнем (рис. 2, слева). Под давлением  $p = 1,0$  МПа, создаваемым рабочей жидкостью, поршень опускается в нижнее положение (рис. 2, справа). При этом мембрана выполняет роль изолятора, не пропуская рабочую жидкость дальше. При опускании поршня мембрана перемещается вместе с ним и давление рабочей жидкости деформирует мембрану, растягивая резину по краям поршня.




Рис. 1




Рис. 2

В этой задаче представляет интерес значение разрушающих напряжений, особенно в области, близкой к креплению мембранны, где происходит основной прогиб резины, ее выворачивание на другую сторону. Также заслуживает внимания область в углах мембранны по краям поршня, где резина под давлением растягивается.

В качестве материала мембранны рассматривается стандартная высокоэластичная резина, имеющая следующие характеристики: модуль Юнга  $E = 4,1 \text{ МПа}$ , предел прочности  $\sigma_y = 17,6 \text{ МПа}$ , удлинение при разрыве  $\varepsilon_y = 6,0$ . При этом предельные разрушающие напряжения определяются из условия слабой сжимаемости резины:

$$\sigma_{\text{пр}} = (\varepsilon_y + 1) \cdot \sigma_y = (6 + 1) \cdot 17,6 = 123 \text{ МПа}.$$

Коэффициент запаса прочности можно определить как

$$s = \frac{\sigma_{\text{пр}}}{\sigma_M},$$

где  $\sigma_M$  — напряжение по Мизесу.

Задача относится к области нелинейной упругости [9—15]. Для ее решения использовалась программа ABAQUS. Резина рассматривалась как нелинейно-упругий слабосжимаемый материал. Для описания упругого поведения резины использовался полиномиальный упругий потенциал

$$U = C_{10}(\bar{I}_1 - 3) + C_{10}(\bar{I}_2 - 3) + C_{20}(\bar{I}_1 - 3)^2 + \frac{1}{D_1}(J^{\text{el}} - 1)^2,$$

где  $\bar{I}_i = I_i / J^{1/3}$ ,  $I_1, I_2$  — инварианты меры деформации Коши — Грина;  $J, J^{\text{el}}$  — третий инвариант градиента места;  $D_1$  — постоянная сжимаемости, зависящая от коэффициента Пуассона и упругих постоянных:

$$D_1 = \frac{3(1-2\nu)}{2(C_{10} + C_{01})(1+\nu)}.$$

Коэффициент Пуассона  $\nu$  принят равным 0,48. Величины упругих постоянных, как правило, определяемые по нагрузочным кривым, для используемой резины следующие:  $C_{10} = 0,6925 \text{ МПа}$ ,  $C_{01} = 0,0261 \text{ МПа}$ ,  $C_{20} = 0,0106 \text{ МПа}$ ;  $D_1 = 0,0585 \text{ МПа}$ .

Задача решается как статическая в осесимметричной постановке. Осесимметричная модель показана на рис. 3. Трение не учитывается. Рассматривается самый опасный вариант при нулевом трении между резиной и металлом.




Рис. 3

Модель состоит из пяти элементов: мембрана, стальной поршень, стальной цилиндр, верхняя стальная планка, стальной фиксатор, необходимый для поджатия мембранны. Отли-

чие модели от чертежа заключается в том, что и поршень, и цилиндр удлинены. Причина в том, что на практике перемещение поршня под давлением начинается сразу с деформацией резины под действием этого давления. В расчетах же сначала подается давление, резина деформируется и только потом происходит перемещение поршня. При коротком поршне до его перемещения при растяжении резины она может выйти за края поршня, чего на самом деле не происходит. Удлинение поршня необходимо, чтобы удержать деформированную мембрану.

Задача решалась в три этапа.

*I этап* — установка мембраны. Осуществляется поджатие резины верхней планкой и фиксатором. Верхняя планка сжимает резину на 1 мм. Фиксатор не перемещается. Задается перемещение вверх цилиндра. Начальное положение цилиндра подобрано так, чтобы он не касался резины.

*II этап* — подача давления  $p$ . Давление подается на свободную наружную стенку мембранны и верхнюю поверхность планки. Поршень, верхняя планка, фиксатор и цилиндр фиксированы.

*III этап* — перекладка мембраны. Задается перемещение поршня вниз. Задаются перемещения поршня и верхней планки. Цилиндр и фиксатор не перемещаются. Давление продолжает действовать на стенку мембранны.

Деформированная модель и поле разрушающих напряжений после I этапа, т.е. после поджатия мембранны, показаны на рис. 4 и 5. Напряжения не велики:  $\sigma_M = 3,5 \text{ МПа}$ , фиксируются в месте, где разрушения не будет.




Рис. 4




Рис. 5

Деформированная модель и поле разрушающих напряжений после подачи давления (после II этапа) показаны на рис. 6; максимальное значение разрушающих напряжений  $\sigma_M = 9,9$  МПа. Деформированная модель и разрушающие напряжения после перекладки мембранны — на рис. 7, максимальное значение разрушающих напряжений  $\sigma_M = 10,9$  МПа.




Рис. 6




Рис. 7

Для наглядности значения разрушающих напряжений сведены в таблицу. Минимальный коэффициент запаса прочности 11,3.

Состояние	$\sigma_M$ , МПа	$s$	$\sigma_{пр}$ , МПа
После подачи давления	9,9	12,4	123
После перекладки мембранны	10,9	11,3	123

Можно сделать вывод, что при давлении  $p = 1,0$  МПа мембрана работоспособна, резина не разрушится. Единственное требование к изменению конструкции — необходимость увеличения длины цилиндра и поршня.

## СПИСОК ЛИТЕРАТУРЫ

1. Колпак Е. П., Мальцева Л. С. Большие деформации резиновых мембран // Молодой ученый. 2014. № 16 (75). С. 78—84 [Электронный ресурс]: <<https://moluch.ru/archive/75/12757/>>, 01.07.2023.
2. Ашайчик А. А., Полонский В. Л. Экспериментальное определение динамических характеристик эластомеров // Решетневские чтения. 2016. Т. 1, № 20. С. 540—542.
3. Ашайчик А. А., Полонский В. Л. Прогнозирование изменения свойств эластомеров при термическом старении // Актуальные проблемы авиации и космонавтики. 2016. Т. 1, № 12. С. 241—243.
4. Полонский В. Л., Тюрин А. П. Проектирование неподвижных уплотнений для подводного нефтедобывающего оборудования // Химическое и нефтегазовое машиностроение. 2017. № 4. С. 44.
5. Polonskii V. L., Tyurin A. P. Design of stationary seals for underwater oil production equipment // Chemical and Petroleum Engineering. 2017. P. 273—278.
6. Полонский В. Л., Тюрин А. П. Проектирование неподвижных уплотнений для подводного нефтедобывающего оборудования // Модели и методы развития технологий машиностроения в условиях цифровизации экономики России: Науч. тр. Высшей школы машиностроения; Под ред. А. А. Поповича. СПб: 2022. С. 14—22.
7. Полонский В. Л., Тарасенко Е. А., Цветкова Г. В. Резиновые амортизаторы малой жесткости для крепления труб // Изв. вузов. Приборостроение. 2020. Т. 63, № 4. С. 378—381.
8. Лепетов В. А. Расчеты и конструирование резиновых конструкционных изделий и форм: Учеб. пособие Л.: Химия, 1972. 312 с.
9. Ашайчик А. А., Полонский В. Л. Расчет деталей машин методом конечных элементов. СПб: Изд-во СПбПУ, 2016. 243 с.
10. Кабриц С. А., Мальков В. М., Мансурова С. Е. Математическое моделирование нелинейной деформации эластомерного слоя // Вестн. Санкт-Петербургского университета. Серия 10: Прикладная математика. Информатика. Процессы управления. 2011. № 3. С. 56—63.
11. Кабриц С. А., Мальков В. М., Мансурова С. Е. Нелинейные уравнения плоского слоя для трех моделей эластомерного материала // Изв. РАН. Механика твердого тела. 2001. № 1. С. 38.
12. Кабриц С. А., Черных К. Ф. Нелинейная теория изотропно упругих тонких оболочек с учетом поперечного сдвига // Изв. РАН. Механика твердого тела. 1996. № 1. С. 124.
13. Колпак Е. П. Устойчивость и закритические состояния безмоментных оболочек при больших деформациях: Автореф. дис. ... д-ра физ.-мат. наук. СПб, 2000.
14. Колпак Е. П. Mathlab: методы вычислений: Учеб. пособие СПб: СПбГУ, 2007.
15. Колпак Е. П. Введение в механику сплошных сред: Учеб. пособие СПб: СПбГУ, 2004.

*Сведения об авторах***Владимир Львович Полонский**

- канд. техн. наук; Санкт-Петербургский политехнический университет Петра Великого, Высшая школа машиностроения, Институт машиностроения, материалов и транспорта; доцент;  
E-mail: vladimir.polonsky@outlook.com

**Елена Александровна Тарасенко**

- канд. техн. наук, доцент; Санкт-Петербургский политехнический университет Петра Великого, Высшая школа машиностроения, Институт машиностроения, материалов и транспорта; доцент;  
E-mail: taraselen@mail.ru,

**Галина Валерьевна Иванова**

- Санкт-Петербургский политехнический университет Петра Великого, Высшая школа машиностроения, Институт машиностроения, материалов и транспорта; старший преподаватель;  
E-mail: galura@yandex.ru

Поступила в редакцию 10.07.2023; одобрена после рецензирования 28.07.2023; принята к публикации 27.09.2023.

## REFERENCES

1. Kolpak E.P. Molodoy uchenyy, 2014, no. 16(75), pp. 78–84, URL: <https://moluch.ru/archive/75/12757/>. (in Russ.)
2. Asheychik A.A., Polonsky V.L. Reshetnevskiy chteniya, 2016, no. 20(1), pp. 540–542. (in Russ.)

3. Asheychik A.A., Polonsky V.L. *Aktual'nyye problemy aviatsii i kosmonavtiki*, 2016, no. 12(1), pp. 241–243. (in Russ.)
4. Polonsky V.L., Tyurin A.P. *Khimicheskoye i neftegazovoye mashinostroyeniye*, 2017, no. 4, pp. 44–47. (in Russ.)
5. Polonskii V.L., Tyurin A.P. *Chemical and Petroleum Engineering*, 2017, pp. 273–278. (in Russ.)
6. Polonskii V.L., Tyurin A.P. *Scientific works of the Higher School of Mechanical Engineering*, St. Petersburg, 2022, pp. 14–22. (in Russ.)
7. Polonsky V.L., Tarasenko E.A., Tsvetkova G.V. *Journal of Instrument Engineering*, 2020, no. 4(63), pp. 378–381. (in Russ.)
8. Lepetov V.A. *Raschety i konstruirovaniye rezinovykh konstruktsionnykh izdeliy i form* (Calculations and Design of Rubber Structural Products and Molds), Leningrad, 1972, 312 p. (in Russ.)
9. Asheychik A.A., Polonsky V.L. *Raschet detaley mashin metodom konechnykh elementov* (Calculation of Machine Parts by the Finite Element Method), St. Petersburg, 2016, 243 p. (in Russ.)
10. Malkov V.M., Kabrits S.A., Mansurova S.E. *Vestnik of Saint Petersburg University. Applied Mathematics. Computer Science. Control Processes*, 2011, no. 3, pp. 56–63. (in Russ.)
11. Kabrits S.A., Malkov V.M., Mansurova S.E. *Mechanics of Solids*, 2001, no. 1, pp. 38. (in Russ.)
12. Kabrits S.A., Chernykh K.F. *Mechanics of Solids*, 1996, no. 1, pp. 124. (in Russ.)
13. Kolpak E.P. *Ustoychivost' i zakriticheskiye sostoyaniya bezmomentnykh obolochek pri bol'sikh deformatsiyakh* (Stability and Supercritical States of Moment-Free Shells under Large Deformations), Doctor's thesis St. Petersburg, 2000. (in Russ.)
14. Kolpak E.P. *Mathlab: metody vychisleniy* (Mathlab: Calculation Methods), St. Petersburg, 2007. (in Russ.)
15. Kolpak E.P. *Vvedeniye v mekhaniku sploshnykh sred* (Introduction to Continuum Mechanics), St. Petersburg, 2004. (in Russ.)

#### *Data on authors*

**Vladimir L. Polonsky**

- PhD; Peter the Great St. Petersburg Polytechnic University, Institute of Mechanical Engineering, Materials and Transport; Higher School of Mechanical Engineering; Associate Professor; E-mail: vladimir.polonsky@outlook.com

**Elena A. Tarasenko**

- PhD, Associate Professor; Peter the Great St. Petersburg Polytechnic University, Institute of Mechanical Engineering, Materials and Transport; Higher School of Mechanical Engineering; Associate Professor; E-mail: taraselen@mail.ru,

**Galina V. Ivanova**

- Peter the Great St. Petersburg Polytechnic University, Institute of Mechanical Engineering, Materials and Transport; Higher School of Mechanical Engineering; Senior Lecturer; E-mail: galura@yandex.ru

Received 10.07.2023; approved after reviewing 28.07.2023; accepted for publication 27.09.2023.