

ISSN 2713-3192  
DOI 10.15622/ia.2022.21.4  
<http://ia.spcras.ru>

ТОМ 21 № 4

# ИНФОРМАТИКА И АВТОМАТИЗАЦИЯ

# INFORMATICS AND AUTOMATION



СПБ ФИЦ РАН



Санкт-Петербург  
2022

# INFORMATICS AND AUTOMATION

Volume 21 № 4, 2022

Scientific and educational journal primarily specialized in computer science, automation, robotics, applied mathematics, interdisciplinary research

Founded in 2002

---

## Founder and Publisher

St. Petersburg Federal Research Center of the Russian Academy of Sciences (SPC RAS)

---

## Editor-in-Chief

**R. M. Yusupov**, Prof., Dr. Sci., Corr. Member of RAS, St. Petersburg, Russia

---

## Editorial Council

|                          |  |
|--------------------------|--|
| <b>A. A. Ashimov</b>     | Prof., Dr. Sci., Academician of the National Academy of Sciences of the Republic of Kazakhstan, Almaty, Kazakhstan |
| <b>N. P. Veselkin</b>    | Prof., Dr. Sci., Academician of RAS, St. Petersburg, Russia  |
| <b>I. A. Kalyaev</b>     | Prof., Dr. Sci., Academician of RAS, Taganrog, Russia  |
| <b>Yu. A. Merkuruyev</b> | Prof., Dr. Sci., Academician of the Latvian Academy of Sciences, Riga, Latvia                                      |
| <b>A. I. Rudskoi</b>     | Prof., Dr. Sci., Academician of RAS, St. Petersburg, Russia  |
| <b>V. Sgurev</b>         | Prof., Dr. Sci., Academician of the Bulgarian Academy of Sciences, Sofia, Bulgaria                                 |
| <b>B. Ya. Sovetov</b>    | Prof., Dr. Sci., Academician of RAE, St. Petersburg, Russia  |
| <b>V. A. Soyfer</b>      | Prof., Dr. Sci., Academician of RAS, Samara, Russia  |

---

## Editorial Board

|                            |   |
|----------------------------|---|
| <b>O. Yu. Gusikhin</b>     | Ph. D., Dearborn, USA   |
| <b>V. Delic</b>            | Prof., Dr. Sci., Novi Sad, Serbia                               |
| <b>A. Dolgui</b>           | Prof., Dr. Sci., St. Etienne, France                            |
| <b>M. N. Favorskaya</b>    | Prof., Dr. Sci., Krasnoyarsk, Russia                            |
| <b>M. Zelezny</b>          | Assoc. Prof., Ph.D., Plzen, Czech Republic                      |
| <b>H. Kaya</b>             | Assoc. Prof., Ph.D., Utrecht, Netherlands                       |
| <b>A. A. Karpov</b>        | Assoc. Prof., Dr. Sci., St. Petersburg, Russia                  |
| <b>S. V. Kuleshov</b>      | Dr. Sci., St. Petersburg, Russia                                |
| <b>A. D. Khomonenko</b>    | Prof., Dr. Sci., St. Petersburg, Russia                         |
| <b>D. A. Ivanov</b>        | Prof., Dr. Habil., Berlin, Germany                              |
| <b>K. P. Markov</b>        | Assoc. Prof., Ph.D., Aizu, Japan                                |
| <b>R. V. Meshcheryakov</b> | Prof., Dr. Sci., Moscow, Russia                                 |
| <b>N. A. Moldovian</b>     | Prof., Dr. Sci., St. Petersburg, Russia                         |
| <b>V. V. Nikulin</b>       | Prof., Ph.D., New York, United States                           |
| <b>V. Yu. Osipov</b>       | Prof., Dr. Sci., St. Petersburg, Russia                         |
| <b>V. K. Pshikhopov</b>    | Prof., Dr. Sci., Taganrog, Russia                               |
| <b>A. L. Ronzhin</b>       | Prof., Dr. Sci., Deputy Editor-in-Chief, St. Petersburg, Russia |
| <b>H. Samani</b>           | Assoc. Prof., Ph.D., Plymouth, UK                               |
| <b>A. V. Smirnov</b>       | Prof., Dr. Sci., St. Petersburg, Russia                         |
| <b>B. V. Sokolov</b>       | Prof., Dr. Sci., St. Petersburg, Russia                         |
| <b>L. V. Utkin</b>         | Prof., Dr. Sci., St. Petersburg, Russia                         |

---

**Editor:** A.S. Lopotova

**Interpreter:** Ya.N. Berezina

**Art editor:** N.A. Dormidontova

---

## Editorial office address

SPC RAS, 14-th line V.O., 39 litera A , St. Petersburg, Russia, 199178

e-mail: [ia@spcras.ru](mailto:ia@spcras.ru), web: <http://ia.spcras.ru>

## The journal is indexed in Scopus

The journal is published under the scientific-methodological supervision of Department for Nanotechnologies and Information Technologies of the Russian Academy of Sciences

© St. Petersburg Federal Research Center of the Russian Academy of Sciences, 2022

# ИНФОРМАТИКА И АВТОМАТИЗАЦИЯ

Том 21 № 4, 2022

Научный, научно-образовательный журнал с базовой специализацией в области информатики, автоматизации, робототехники, прикладной математики и междисциплинарных исследований.

Журнал основан в 2002 году

## Учредитель и издатель

Федеральное государственное бюджетное учреждение науки  
«Санкт-Петербургский Федеральный исследовательский центр Российской академии наук»  
(СПб ФИЦ РАН)

## Главный редактор

Р. М. Юсупов, чл.-корр. РАН, д-р техн. наук, проф., Санкт-Петербург, РФ

## Редакционный совет

|                 |  |
|-----------------|--|
| А. А. Ашимов    | академик Национальной академии наук Республики Казахстан, д-р техн. наук, проф., Алматы, Казахстан |
| Н. П. Веселкин  | академик РАН, д-р мед. наук, проф., Санкт-Петербург, РФ  |
| И. А. Каляев    | академик РАН, д-р техн. наук, проф., Таганрог, РФ  |
| Ю. А. Меркурьев | академик Латвийской академии наук, д-р, проф., Рига, Латвия  |
| А. И. Рудской   | академик РАН, д-р техн. наук, проф., Санкт-Петербург, РФ   |
| В. Сгурев       | академик Болгарской академии наук, д-р техн. наук, проф., София, Болгария                          |
| Б. Я. Советов   | академик РАН, д-р техн. наук, проф., Санкт-Петербург, РФ   |
| В. А. Сойфер    | академик РАН, д-р техн. наук, проф., Самара, РФ  |

## Редакционная коллегия

|                  |   |
|------------------|---|
| О. Ю. Гусихин    | д-р наук, Диаборн, США  |
| В. Делич         | д-р техн. наук, проф., Нови-Сад, Сербия                             |
| А. Б. Долгий     | д-р наук, проф. Сент-Этьен, Франция                                 |
| М. Железны       | д-р наук, доцент, Пльзень, Чешская республика                       |
| Д. А. Иванов     | д-р экон. наук, проф., Берлин, Германия                             |
| Х. Кайя          | д-р наук, доцент, Утрехт, Нидерланды                                |
| А. А. Карпов     | д-р техн. наук, доцент, Санкт-Петербург, РФ                         |
| С. В. Кулешов    | д-р техн. наук, Санкт-Петербург, РФ                                 |
| К. П. Марков     | д-р наук, доцент, Аизу, Япония                                      |
| Р. В. Мещеряков  | д-р техн. наук, проф., Москва, РФ                                   |
| Н. А. Молдовян   | д-р техн. наук, проф., Санкт-Петербург, РФ                          |
| В.В. Никулин     | д-р наук, проф., Нью-Йорк, США                                      |
| В.Ю. Осипов      | д-р техн. наук, проф., Санкт-Петербург, РФ                          |
| В. Х. Пшихолопов | д-р техн. наук, проф., Таганрог, РФ                                 |
| А. Л. Ронжин     | д-р техн. наук, проф., зам. главного редактора, Санкт-Петербург, РФ |
| Х. Самани        | д-р наук, доцент, Плимут, Соединённое Королевство                   |
| А. В. Смирнов    | д-р техн. наук, проф., Санкт-Петербург, РФ                          |
| Б. В. Соколов    | д-р техн. наук, проф., Санкт-Петербург, РФ                          |
| Л. В. Уткин      | д-р техн. наук, проф., Санкт-Петербург, РФ                          |
| М. Н. Фаворская  | д-р техн. наук, проф., Красноярск, РФ                               |
| А. Д. Хомоненко  | д-р техн. наук, проф., Санкт-Петербург, РФ                          |
| Л. Б. Шереметов  | д-р техн. наук, Мехико, Мексика                                     |

Выпускающий редактор: А.С. Лопотова

Переводчик: Я.Н. Березина

Художественный редактор: Н.А. Дормидонтова

## Адрес редакции

199178, г. Санкт-Петербург, 14-я линия В.О., д. 39, литер А

e-mail: ia@spcras.ru, сайт: <http://ia.spcras.ru>

## Журнал индексируется в международной базе данных Scopus

Журнал входит в «Перечень ведущих рецензируемых научных журналов и изданий, в которых должны быть опубликованы основные научные результаты диссертации на соискание ученой степени доктора и кандидата наук»

Журнал выпускается при научно-методическом руководстве Отделения нанотехнологий и информационных технологий Российской академии наук

© Федеральное государственное бюджетное учреждение науки

«Санкт-Петербургский Федеральный исследовательский центр Российской академии наук», 2022  
Разрешается воспроизведение в прессе, а также сообщение в эфир или по кабелю опубликованных в составе печатного периодического издания - журнала «ИНФОРМАТИКА И АВТОМАТИЗАЦИЯ» статей по текущим экономическим, политическим, социальным и религиозным вопросам с обязательным указанием имени автора статьи и печатного периодического издания журнала «ИНФОРМАТИКА И АВТОМАТИЗАЦИЯ»

## CONTENTS

### **Artificial Intelligence, Knowledge and Data Engineering**

A. Popkov, Yu. Dubnov, Yu. Popkov  
RANDOMIZED MACHINE LEARNING AND FORECASTING OF  
NONLINEAR DYNAMIC MODELS APPLIED TO SIR EPIDEMIOLOGICAL  
MODEL 659

I. Kipyatkova, I. Kagirov  
ANALYTICAL REVIEW OF METHODS FOR SOLVING DATA SCARCITY  
ISSUES REGARDING ELABORATION OF AUTOMATIC SPEECH  
RECOGNITION SYSTEMS FOR LOW-RESOURCE LANGUAGES 678

A. Mahamudul Hashan, R. Md Rakib Ul Islam, K. Avinash  
APPLE LEAF DISEASE CLASSIFICATION USING IMAGE DATASET: A  
MULTILAYER CONVOLUTIONAL NEURAL NETWORK APPROACH 710

### **Robotics, Automation and Control Systems**

O. Darintsev, A. Migranov  
ANALYTICAL REVIEW OF APPROACHES TO THE DISTRIBUTION OF  
TASKS FOR MOBILE ROBOT TEAMS BASED ON SOFT COMPUTING  
TECHNOLOGIES 729

M. Ivanov, A. Polunin  
IMPROVING THE ACCURACY OF IP GEOLOCATION BASED ON PUBLIC  
IP GEOSERVICES DATA 758

R. Abdullaev  
METHOD FOR DETERMINING THE FUNCTIONAL DEPENDENCES OF  
WORKING OUTPUTS OF LOGIC COMBINATION SCHEMES FOR  
DEVELOPMENT UNIDIRECTIONAL ERRORS 786

A. Pavlov, D. Pavlov, A. Umarov, A. Gordeev  
METHOD OF STRUCTURAL-PARAMETRIC SYNTHESIS OF  
CONFIGURATION MULTI-MODE OBJECT 812

## СОДЕРЖАНИЕ

### **Искусственный интеллект, инженерия данных и знаний**

А.Ю. Попков, Ю.А. Дубнов, Ю.С. Попков  
РАНДОМИЗИРОВАННОЕ МАШИННОЕ ОБУЧЕНИЕ И  
ПРОГНОЗИРОВАНИЕ НЕЛИНЕЙНЫХ ДИНАМИЧЕСКИХ МОДЕЛЕЙ С  
ПРИМЕНЕНИЕМ К ЭПИДЕМИОЛОГИЧЕСКОЙ МОДЕЛИ SIR 659

И.С. Кипяткова, И.А. Кагиров  
АНАЛИТИЧЕСКИЙ ОБЗОР МЕТОДОВ РЕШЕНИЯ ПРОБЛЕМЫ МАЛЫХ  
НАБОРОВ ДАННЫХ ПРИ СОЗДАНИИ СИСТЕМ АВТОМАТИЧЕСКОГО  
РАСПОЗНАВАНИЯ РЕЧИ ДЛЯ МАЛОРЕСУРСНЫХ ЯЗЫКОВ 678

А. Махмудул Хасан, Р. Мд Ракиб Ул Ислам, К. Авинаш  
КЛАССИФИКАЦИЯ БОЛЕЗНЕЙ ЛИСТЬЕВ ЯБЛОНИ С  
ИСПОЛЬЗОВАНИЕМ НАБОРА ДАННЫХ ИЗОБРАЖЕНИЙ: ПОДХОД  
МНОГОСЛОЙНОЙ СВЕРТОЧНОЙ НЕЙРОННОЙ СЕТИ 710

### **Робототехника, автоматизация и системы управления**

О.В. Даринцев, А.Б. Мигранов  
АНАЛИТИЧЕСКИЙ ОБЗОР ПОДХОДОВ К РАСПРЕДЕЛЕНИЮ ЗАДАЧ В  
ГРУППАХ МОБИЛЬНЫХ РОБОТОВ НА ОСНОВЕ ТЕХНОЛОГИЙ  
МЯГКИХ ВЫЧИСЛЕНИЙ 729

М.В. Иванов, А.А. Полунин  
ПОВЫШЕНИЕ ТОЧНОСТИ IP-ГЕОЛОКАЦИИ НА ОСНОВЕ ДАННЫХ,  
ПРЕДОСТАВЛЯЕМЫХ ОТКРЫТЫМИ IP-ГЕОСЕРВИСАМИ 758

Р.Б. Абдуллаев  
МЕТОД ОПРЕДЕЛЕНИЯ ФУНКЦИОНАЛЬНОЙ ЗАВИСИМОСТИ  
РАБОЧИХ ВЫХОДОВ ЛОГИЧЕСКИХ КОМБИНАЦИОННЫХ СХЕМ ОТ  
ПРОЯВЛЕНИЯ МОНОТОННЫХ ОШИБОК 786

А.Н. Павлов, Д.А. Павлов, А.Б. Умаров, А.В. Гордеев  
МЕТОД СТРУКТУРНО-ПАРАМЕТРИЧЕСКОГО СИНТЕЗА  
КОНФИГУРАЦИЙ МНОГОРЕЖИМНОГО ОБЪЕКТА 812

А.Ю. Попков, Ю.А. Дубнов, Ю.С. Попков  
**РАНДОМИЗИРОВАННОЕ МАШИННОЕ ОБУЧЕНИЕ И  
ПРОГНОЗИРОВАНИЕ НЕЛИНЕЙНЫХ ДИНАМИЧЕСКИХ  
МОДЕЛЕЙ С ПРИМЕНЕНИЕМ К ЭПИДЕМИОЛОГИЧЕСКОЙ  
МОДЕЛИ SIR**

---

*Попков А.Ю., Дубнов Ю.А., Попков Ю.С. Рандомизированное машинное обучение и прогнозирование нелинейных динамических моделей с применением к эпидемиологической модели SIR.*

**Аннотация.** В работе предлагается подход к оцениванию параметров нелинейных динамических моделей с помощью концепции Рандомизированного машинного обучения (РМО), основанной на переходе от детерминированных моделей к случайным (со случайными параметрами) с последующим оцениванием вероятностных распределений параметров и шумов по реальным данным. Главной особенностью данного метода является его эффективность в условиях малого количества реальных данных. В работе рассматриваются модели, сформулированные в терминах обыкновенных дифференциальных уравнений, которые преобразуются к дискретному виду для постановки и решения задачи энтропийной оптимизации. Применение предлагаемого подхода демонстрируется на задаче прогнозирования общего количества инфицированных COVID-19 с помощью динамической эпидемиологической модели SIR. Для этого в работе строится рандомизированная модель SIR (R-SIR) с одним параметром, энтропийно-оптимальная оценка которого реализуется его функцией плотности распределения вероятностей, а также функциями плотности распределения вероятностей измерительных шумов в точках, в которых производится обучения. Далее применяется техника рандомизированного прогнозирования с фильтрацией шумов, основанная на генерации соответствующих распределений и построении ансамбля прогнозных траекторий с вычислением средней по ансамблю траектории. В работе реализуется вычислительный эксперимент с использованием реальных оперативных данных о заболеваемости в виде сравнительного исследования с известным методом оценивания параметров модели, основанным на методе наименьших квадратов. Полученные в эксперименте результаты демонстрируют существенное снижение средне-абсолютной процентной ошибки (MAPE) при по отношению к реальным наблюдениям на интервале прогноза, что показывают работоспособность предложенного метода и его эффективность в задачах рассматриваемого в работе типа.

**Ключевые слова:** рандомизированное машинное обучение, энтропия, энтропийное оценивание, прогнозирование, рандомизированное прогнозирование.

---

**1. Введение.** Традиционно, все нелинейные случаи представляют собой трудоемкие задачи, основным подходом к решению которых до сих пор остается подход, основанный на переходе к линейным зависимостям с помощью переформулировки задач, ввода некоторых допущений, которые делают возможной линеаризацию используемых функциональных объектов и т.п.

Тем не менее, многие практические задачи, связанные с различными процессами, которые требуется моделировать, очевидно содержат в себе

нелинейные процессы, эффекты и связи, работа с которыми напрямую, без линеаризации, была бы предпочтительна. Разумеется, при условии эффективной возможности получения полезных результатов.

Одной из таких задач является задача прогнозирования количества инфицированных при распространении какого либо заболевания. Существенную актуальность данная задача получила при возникновении пандемии новой коронавирусной инфекции и вызываемой ей болезни COVID-19, которая к настоящему времени далека не только от завершения, но и от надежного контролирования. До сих пор не разработан единый эффективный подход к моделированию процесса распространения этой инфекции, но наиболее распространенная группа подходов к решению этой проблемы основана на использовании «золотого стандарта» эпидемиологии, а именно компартментных эпидемиологических моделей [2]. Эта группа моделей математически реализована в виде системы нелинейных дифференциальных уравнений, параметры которых необходимо настроить по реальным данным.

Стандартный путь решения этой формальной задачи основан на использовании метода наименьших квадратов, после чего, модель с оптимальными значениями параметров используется для прогнозирования [3–5]. При всей эффективности и теоретической обоснованности данного подхода, он не лишен недостатков, особенно в контексте нелинейных моделей, главным из которых является доказательность свойств получаемых оценок параметров и соответствующих им прогнозов. Эта проблема в той или иной степени успешно решается в рамках методов машинного обучения, также основанных на статистической теории, тем не менее, предполагающих определенные свойства используемых данных типа нормальности [6–8]. В рамках практических применений методов машинного обучения обычно эта проблема решается путем нормализации данных, что становится возможным в условиях, когда элементов данных много. В условиях же малого количества данных и при неизвестном механизме их генерации (а точнее, механизме генерации их стохастической составляющей) актуализируется проблема разработки новых подходов к решению задач в таких условиях.

Теория рандомизированного машинного обучения [9] ориентирована на решение задач с малым количеством данным без учета их вероятностных свойств. В [10] этот подход применялся к решению задач с линейными динамическими моделями, в [1] к задаче прогнозирования развития эпидемии COVID-19 с использованием статических моделей. В данной работе предлагается развитие метода энтропийного оценивания параметров нелинейных моделей [11] в направлении оценивания параметров

нелинейных динамических моделей, основанных на дифференциальных уравнениях.

**2. Постановка задачи.** Рассмотрим объект, описываемый моделью в виде «вход-выход»:

$$y = F(x, a), \quad (1)$$

где векторы  $y$ ,  $x$  и  $a$  определяют выход, вход и параметры модели соответственно, вектор-функция  $F$  реализует связь между входом и выходом. Предполагается, что выход объекта в процессе своего функционирования «наблюдается» и «измеряется», в результате образуется массив его измерений.

Функциональная связь, реализуемая в модели вектор-функцией  $F$ , может быть статической, когда следующее значение выхода предполагается зависящим только от текущего значения входа, и динамической, когда следующее значение выхода зависит от нескольких значений входа. Статические и динамические связи входа и выхода модели следует понимать в общем смысле без привязки к временной шкале и т.п. Объектом исследования настоящей работы являются динамические модели.

Традиционно, динамические объекты принято реализовывать с помощью дифференциальных уравнений. В связи с этим, рассмотрим обыкновенное дифференциальное уравнение первого порядка в виде:

$$\frac{dx}{dt} = \Phi(t, x, a), \quad (2)$$

где  $x$  реализует состояние исследуемого объекта,  $a$  — параметр. В общем случае все величины кроме времени  $t$  могут быть векторными, а  $\Phi$  в том числе и нелинейная.

Для перехода от представления (2) в виде дифференциального уравнения к виду (1) используем схему Эйлера с шагом  $h$ :

$$y[n + 1] = y[n] + h\Phi(t[n], y[n], a) = F(x, a), \quad (3)$$

где  $n$  является индексом текущего узла равномерной сетки с шагом  $h$  и:

$$F(x, a) = y[n] + h\Phi(t[n], y[n], a), \quad x = (t[n], x[n], y[n]).$$

Здесь и далее будем использовать систему обозначений, которая предполагает обозначение соответствующих значений величин в узлах реальной или виртуальной дискретной сетки в виде имени величины с индексом узла в квадратных скобках. Эти обозначения не подразумевают,



что все используемые величины дискретны, а подразумевают обозначение значений этих величин в конкретных точках.

**3. Энтропийное оценивание параметров.** Энтропийное оценивание параметров модели, подробно описанное в работах [9, 11, 12], базируется на переходе от модели с детерминированными параметрами к модели со случайными параметрами. Этот переход называется *рандомизацией* и состоит в придании неслучайным объектам случайных свойств.

Для реализации этого перехода с дальнейшей постановкой и решением оптимизационной задачи требуется использование модели в виде «вход-выход». В случае рассматриваемой здесь реализации динамических моделей в виде обыкновенных дифференциальных уравнений (ОДУ), будем использовать представление (3).

Рандомизация приводит к тому, что параметры модели рассматриваются случайными величинами со значениями из заданных интервалов и соответствующими распределениями вероятностей. То же касается и шума, который добавляется к выходу модели в каждой точке, в которой происходит оценивание. В непрерывном случае распределения будут определяться соответствующими функциями плотности распределения вероятностей (ПРВ), которые требуется оценить.

Таким образом, параметры и шумы полученной *рандомизированной модели* (PM) будут иметь вид:

$$\mathbf{a} \sim P(\mathbf{a}), \quad \mathbf{a} \in \mathcal{A} \in R^d, \quad (4)$$

$$\xi \sim Q(\xi), \quad \xi \in \Xi \in R^m, \quad (5)$$

где  $d$  — размерность пространства параметров,  $m$  — количество точек оценивания и, соответственно, размерность пространства шумов. Здесь и далее полужирным шрифтом будет обозначать векторные величины из соответствующих пространств.

Интервалы параметров в общем случае предполагаются разными, что касается шумов, то в зависимости от интерпретации механизма возникновения шума, они также могут быть различными:

$$a_i \in A_i = [a_i^-, a_i^+], \quad \mathcal{A} = \bigotimes_{i=1}^d A_i, \quad (6)$$

$$\xi_j \in \Xi_j = [\xi_j^-, \xi_j^+], \quad \Xi = \bigotimes_{j=1}^m \Xi_j. \quad (7)$$

Предполагая независимость измерений выхода модели, совместное распределение шумов во всех точках реализуется произведением отдельных распределений (функций плотности), в то время как предполагать независимость каждой компоненты параметров в общем случае нельзя:

$$Q(\boldsymbol{\xi}) = \prod_{j=1}^m q_j(\xi_j). \quad (8)$$

В результате, модель (1) представляется в виде:

$$\mathbf{v} = F(\mathbf{x}, \mathbf{a}) + \boldsymbol{\xi}, \quad (9)$$

где  $\mathbf{v} \in R^m$  — зашумленный выход модели,  $\boldsymbol{\xi} \in R^m$  — вектор шумов.

Следуя концепции рандомизированного машинного обучения (РМО) [9], основанной на энтропийной оценке параметров модели, которая состоит в максимизации информационной энтропии распределений параметров и шумов при условии их нормировки и балансе среднего выхода с наблюдаемым выходом модели (реальными данными), сформулируем соответствующую задачу оптимизации:

$$H(P, Q) = - \left[ \int_{\mathcal{A}} P(\mathbf{a}) \ln P(\mathbf{a}) d\mathbf{a} + \int_{\Xi} Q(\boldsymbol{\xi}) \ln Q(\boldsymbol{\xi}) d\boldsymbol{\xi} \right] \rightarrow \max_{P, Q}, \quad (10)$$

$$\int_{\mathcal{A}} P(\mathbf{a}) d\mathbf{a} = 1, \quad \int_{\Xi_j} q_j(\xi_j) d\xi_j = 1, \quad (11)$$

$$\int_{\mathcal{A}} F(\mathbf{x}_j, \mathbf{a}) P(\mathbf{a}) d\mathbf{a} + \int_{\Xi} \xi_j q_j(\xi_j) d\xi_j = \hat{y}_j, \quad j = \overline{1, m}, \quad (12)$$

где  $\hat{y}_j$  — наблюдаемый выход модели в  $j$ -й точке (реальные данные).

Решая эту задачу методом множителей Лагранжа, получим энтропийно-оптимальные функции плотности параметров и шумов:

$$P^*(\mathbf{a}, \lambda) = \frac{\exp \left( - \sum_{j=1}^m \lambda_j F(\mathbf{x}_j, \mathbf{a}) \right)}{\int_{\mathcal{A}} \exp \left( - \sum_{j=1}^m \lambda_j F(\mathbf{x}_j, \mathbf{a}) \right) d\mathbf{a}}, \quad (13)$$

$$q_j^*(\xi_j, \lambda) = \frac{\exp(-\lambda_j \xi_j)}{\int_{\Xi_j} \exp(-\lambda_j \xi_j) d\xi_j}, \quad j = \overline{1, m}, \quad (14)$$

где  $\lambda = \{\lambda_j\}$ .

Подставляя выражения (13)-(14) в (12), получим уравнение для определения множителей:

$$\frac{\int_{\mathcal{A}} F(\mathbf{x}_j, \mathbf{a}) \exp\left(-\sum_{j=1}^m \lambda_j F(\mathbf{x}_j, \mathbf{a})\right) d\mathbf{a}}{\int_{\mathcal{A}} \exp\left(-\sum_{j=1}^m \lambda_j F(\mathbf{x}_j, \mathbf{a})\right) d\mathbf{a}} + \frac{\int_{\Xi_j} \xi_j \exp(-\lambda_j \xi) d\xi}{\int_{\Xi_j} \exp(-\lambda_j \xi) d\xi} = \hat{y}_j. \quad (15)$$

Учитывая сложную нелинейную структуру этого уравнения и наличие интегральных компонент, решать ее на практике необходимо численно. Следует также отметить, что в большинстве программных средств, реализующих численные методы, существует возможность вычисления интегралов размерности не более 3. В условиях, когда модель содержит параметры размерности больше 3, с точки зрения эффективности вычислений следует переходить к дискретным распределениям и соответствующим вычислительным задачам [13].

**4. Прогнозирование общего количества инфицированных с использованием динамической эпидемиологической модели.** Для демонстрации предлагаемого подхода рассмотрим задачу прогнозирования общего количества инфицированных при распространении инфекционного заболевания, которая становится особенно актуальной в настоящее время в связи с продолжающейся пандемией COVID-19. Одним из основных подходов к моделированию и последующему прогнозированию этого процесса является использование динамических моделей, основанных на дифференциальных уравнениях и имеющих длинную историю [2, 14]. Этот класс моделей активно используется в настоящее время на уровне правительств для оценки и прогнозирования развития эпидемии COVID-19. Основная идея, на которых построены эти модели, состоит в разделении популяции на непересекающиеся группы (компарменты) с дальнейшим построением и оценкой характеристик перехода членов популяции из одной группы в другую. В настоящее время существуют модели со множеством различных групп, например, госпитализированных, госпитализированных в отделение реанимации и интенсивной терапии (ОРИТ), легких и средне-тяжелых больных и т.п. Здесь рассмотрим наиболее распространенную модель с тремя компарментами.

**4.1. Модель.** Для моделирования развития эпидемии COVID-19 будем использовать модель SIR, являющуюся «золотым стандартом» современной эпидемиологии [2, 15, 16]. Она реализуется системой нелинейных дифференциальных уравнений:

$$\frac{dS}{dt} = -\beta SI, \quad \frac{dI}{dt} = \beta SI - \gamma I, \quad \frac{dR}{dt} = \gamma I, \quad S(0) = 1. \quad (16)$$

Модель основана на трех группах (компартаментах): уязвимых (Susceptible), инфицированных (Infected), удаленных (Removed). В группе S находятся люди, не имеющие иммунитета к инфекции, в группу I попадают заболевшие (инфицированные), в группу R — умершие и выздоровевшие.

В модели есть два параметра:  $\beta$ , называемый transmission rate, характеризует скорость передачи инфекции от одного члена популяции к другому и определяется как среднее количество контактов человека за единицу времени  $\times$  вероятность передачи инфекции в результате контакта; в итоге он определяет среднее количество зараженных от одного инфицированного, и  $\gamma$ , называемый recovery rate, который характеризует перемещение из группы I в группу R.

На основе этих параметров определяются основные индикаторы эпидемии:  $d = 1/\gamma$  — средний инфекционный период (mean infectious period), в течении которого человек может распространять инфекцию, и основное репродуктивное число (basic reproduction number)  $R_0 = \beta/\gamma$ . Последний показывает, сколько человек каждый инфицированный может заразить за период  $d$ .

Параметр  $\gamma$  является характеристикой самой инфекции, в то время как  $\beta$  зависит не только от свойств инфекции, но и от структуры общества, плотности населения, структуры рынка труда, потоков общественного транспорта и также большого количества иных факторов, которые составляют типичную жизнь современного городского жителя. Также этот показатель можно использовать, чтобы анализировать развитие эпидемии со временем, а также оценивать эффективность принимаемых для борьбы с ней мер.

Очевидный подход, который стал применяться в начале эпидемии COVID-19 практически по всему миру, состоял как в оценке  $\beta$ , так и в оценке  $\gamma$ , т.к. инфекция, с которой столкнулось человечество, была неизвестна [17, 18]. К настоящему времени, после появления и распространения уже нескольких отдельных штаммов вируса SARS-CoV-2 параметр  $\gamma$  в среднем был вполне надежно оценен для каждого из штаммов [19–22]. Однако, параметр  $\beta$  по-прежнему требуется оценивать по наблюдениям за оперативными данными с тем, чтобы повысить точность модели (16). В

этой связи, далее будем рассматривать параметр  $\gamma$  фиксированным и равным 0.1, что соответствует инфекционному периоду продолжительностью 10 дней (этот период был установлен для первого, уханьского штамма).

Задача состоит в том, чтобы оценить (обучить модель) параметр  $\beta$  по наблюдениям за общим количеством инфицированных.

Для перехода к модели в виде «вход-выход» используем схему Эйлера с шагом  $h$  и получим следующую систему разностных уравнений:

$$\begin{aligned} S[k] &= S[k-1] - h\beta S[k-1]I[k-1], \\ I[k] &= I[k-1] + h(\beta S[k-1]I[k-1] - \gamma I[k-1]), \\ R[k] &= R[k-1] + h\gamma I[k-1], \end{aligned} \quad (17)$$

где  $k$  обозначает индекс узла сетки.

Эти выражения будем использовать в дальнейшем для обучения методом наименьших квадратов и построения и обучения рандомизированной модели.

**4.2. Данные.** В вычислительных экспериментах используются оперативные данные по Германии, собираемые сервисом Data Hub [23,24]. Самыми надежными оперативными данными об эпидемии являются дневные данные о регистрируемых случаях и смертях. Далее будем использовать следующие обозначения для наборов данных, полученных из первичных оперативных данных:

- Дневные абсолютные;
- Confirmed (Cd) — Количество инфицированных (случаев);
- Deaths (Dd) — Количество умерших;
- Recovered (Rd) — Количество выздоровевших;
- Дневные 7-дневные средние Cd\_avg, Dd\_avg, Rd\_avg;
- Накопленные (общие, куммулятивные) C, D, R;
- Дневные относительные Cd/N, Dd/N, Rd/N и общие относительные C/N, D/N, R/N, где N — численность населения в изучаемой стране, на момент исследования для Германии  $N = 82,905,782$  человек.

На рисунке 1 представлены используемые оперативные данные по Германии с начала эпидемии COVID-19. На рисунке слева представлены дневные данные с 7-дневным скользящим средним, справа — общие (кумулятивные) данные.

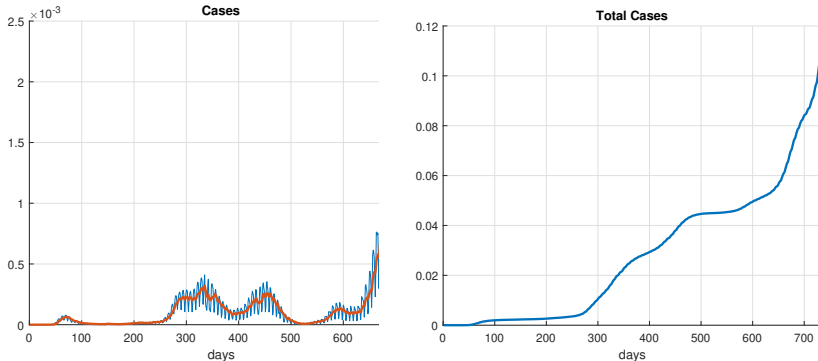


Рис. 1. Оперативные данные о случаях заболевания в Германии с начала эпидемии COVID-19

Модель SIR показывает динамику соответствующих частей популяции, следовательно, для обучения модели необходимо использовать общие (накопленные) данные на душу населения (относительные), которые в принятой концепции являются наблюдаемыми данными по траектории  $I$  в (16). Использование относительных данных позволяет работать в масштабе  $[0,1]$ , а также сравнивать динамику в разных регионах (странах) из-за различий в численности населения.

Общие данные по дням вычисляются по 7-дневному среднему из дневных данных следующим образом:

$$C[n] = \frac{1}{N} \sum_{k=1}^{n-1} Cd\_avg[k],$$

где  $n$  — индекс дня наблюдений, и выравниваются таким образом, чтобы начало данных приходилось на понедельник (первый день недели).

Необходимо отметить, что в настоящее время эпидемиологические данные и модели как правило оперируют именно недельными показателями вследствие специфики сбора данных в течении недели: выписка пациентов происходит во многих странах в воскресенье или понедельник, тестирование более активное в конце недели, в некоторых странах пятница и суббота — выходные дни и т.д.

В обучении использовались 4 точки данных (5 для обучения МНК, см. ниже), соответствующие началу недели, начиная с 230 дня от начала эпидемии (33 неделя).

**4.3. Обучение модели методом наименьших квадратов.** Для реализации сравнительного исследования проводится обучение модели на том же наборе данных с помощью нелинейного метода наименьших квадратов (МНК) [6–8, 25].

Оценивание МНК производится в окне длиной 4 недели, используются недельные данные, соответствующие началу недели (5 точек данных), параметр  $\gamma = 0.1$ , оценивается только  $\beta$ . Задача оптимизации  $\beta$  с использованием средне-абсолютной процентной ошибки MAPE (Mean Absolute Percentage Error) формулируется следующим образом:

$$\beta^* = \arg \min_{\beta} \sum_{n=1}^M \left( \frac{I[n] - C[n]}{C[n]} \right)^2. \quad (18)$$

Для вычисления выхода модели в точках оценивания требуется решать систему ОДУ в окне каким-либо численным методом. Здесь будем использовать метод Эйлера с параметром  $h = 0.1$ , который определен экспериментально с помощью сравнения решения данной задачи на используемом наборе данных методом Рунге-Кутты, реализованным функцией `ode45` на платформе MATLAB.

Необходимо отметить, что сетка решения ОДУ существенно мельче дневной шкалы данных, но обучение производится только в требуемых точках, соответствующих началу недели.

**4.4. Рандомизированное обучение и прогнозирование.** Для построения *рандомизированной модели SIR (R-SIR)*, используем модель (17) для  $I$  с рандомизированным параметром  $\beta$ . Обозначим выход модели через  $y$ , вектор входа  $\mathbf{x} = (S, I)$  и  $y = I$ , тогда:

$$y = F(\mathbf{x}, \beta) = x_2 + h(\beta x_1 x_2 - \gamma x_2). \quad (19)$$

Обучение модели производится в тех же точках, что и при обучении МНК, следовательно входами РМ будут значения траекторий  $S$  и  $I$  в предыдущих точках на сетке решения ОДУ (17).

Для всех точек на интервале обучения будем использовать шум в пределах 30% во всех точках, а интервалы параметров установим в пределах 50% от оптимального  $\beta^*$ , полученного с помощью МНК (далее будем использовать обозначение  $\beta_{ols}$  для этого значения).

Следуя (10)-(12) сформулируем задачу энтропийной оптимизации для вычисления оценок распределений (функций ППВ)  $P(\beta)$  параметра  $\beta$  и шумов измерений  $q_j(\xi)$ :

$$H(P, Q) = - \left[ \int_{\mathcal{A}} P(\beta) \ln P(\beta) d\beta + \int_{\Xi} Q(\xi) \ln Q(\xi) d\xi \right] \rightarrow \max_{P, Q}, \quad (20)$$

$$\int_{\mathcal{A}} P(\beta) d\beta = 1, \quad \int_{\Xi} q_j(\xi) d\xi = 1, \quad (21)$$

$$\int_{\mathcal{A}} F(x_j, \beta) P(\beta) d\beta + \int_{\Xi} \xi q_j(\xi) d\xi = C_j, \quad (22)$$

где через  $C_j$  обозначены значения общих случаев заболевания в точках обучения.

Решая эту задачу методом множителей Лагранжа, получим энтропийно-оптимальные распределения параметра  $\beta$  и шумов:

$$P^*(\beta, \lambda) = \frac{\exp \left( - \sum_{j=1}^m \lambda_j F(\mathbf{x}_j, \beta) \right)}{\int_{\mathcal{A}} \exp \left( - \sum_{j=1}^m \lambda_j F(\mathbf{x}_j, \beta) \right)}, \quad (23)$$

$$q_j^*(\xi, \lambda) = \frac{\exp(-\lambda_j \xi)}{\int_{\Xi} \exp(-\lambda_j \xi)}, \quad j = \overline{1, m}, \quad (24)$$

где:

$$F(\mathbf{x}_j, \beta) = F(\mathbf{x}[k], \beta) = I[k-1] + h(\beta S[k-1] I[k-1] - \gamma I[k-1]). \quad (25)$$

Согласно принятой в машинном обучении методике, связанной с тестированием модели на тестовом наборе данных, построенную и обученную модель необходимо протестировать на наборе данных, не использовавшихся при обучении. Рассматриваемая здесь задача характеризуется малым набором данных, используемым для обучения, к тому же, сама постановка задачи и подход к ее решению, демонстрируемый здесь, не предполагает, что отдельные данные для тестирования перед прогнозированием доступны. В этой связи, под тестированием здесь будем понимать реализацию модели на интервале обучения с вычислением ошибок MAPE.



Прогнозирование с использованием рандомизированной модели осуществляется методом рандомизированного прогнозирования, описанным в [9, 13]. Он состоит в сэмплировании соответствующих распределений с последующим построением ансамбля прогнозных траекторий. Здесь существует несколько подходов к ее построению, в настоящей работе используется средняя по ансамблю траектория. Сэмплирование непрерывного распределения  $P(\beta)$  осуществляется методом Acceptance-Rejection (AR) [26]. Распределения шумов, получаемых при обучении РМ, при прогнозе не используются, таким образом осуществляется фильтрация шумов в данных, реализующих неопределенность в них.

**5. Результаты.** Реализация всех вычислительных экспериментов была проведена на платформе MATLAB 9.7 (2019b) с использованием пакетов Optimization и Curve Fitting соответствующих версий.

В результате обучения МНК оптимальное значение  $\beta_{ols} = 0,1070$ . Интервалы параметров, использующиеся для рандомизированного обучения, показаны в таблице 1.

Таблица 1. Интервалы параметров и шумов рандомизированной модели

| $\beta_{ols}$ | $\beta^-$ | $\beta^+$ | $\xi^-$ | $\xi^+$ |
|---------------|-----------|-----------|---------|---------|
| 0.1070        | 0.0538    | 0.1613    | -0.3    | 0.3     |

Результаты обучения приведены на рисунке 2, реальные данные (наблюдения) с меткой `real`, траектории, полученные при обучении МНК с меткой `ols`, средняя рандомизированная траектория с меткой `avg`, также представлен ансамбль траекторий и область стандартного отклонения, вычисленная по нему.

Результаты прогнозирования представлены на рисунке 3. Показан рандомизированный прогноз общего количества заболевших  $I_{mee}$  и прогноз МНК  $I_{ols}$ . Среднее по распределению значение параметра  $\beta_{mean} = 0.1091$ , что говорит о том, что рандомизированный прогноз отличается от стандартного, полученного МНК. Ошибки на интервале обучения составили  $\delta_{ols}^{train} < 0.01$ ,  $\delta_{mee}^{train} = 0,11$ , на интервале прогноза:  $\delta_{ols}^{pred} = 0,29$ ,  $\delta_{ols}^{pred} = 0,03$ .

**6. Заключение.** Полученные результаты показывают, что предлагаемый в работе подход, основанный на энтропийном оценивании параметров и рандомизированном прогнозировании, является эффективным в задачах, подобных рассмотренной.




Рис. 2. Результаты обучения




Рис. 3. Результаты прогнозирования

Эти задачи характеризуются, с одной стороны, малым количеством наблюдений, с другой стороны — процессом непознанной природы, вследствие чего данные наблюдений не могут надежно считаться качественными с статистическим смыслом. Описание подобных процессов с помощью динамических моделей является популярным и эффективным подходом, однако, необходимо качественно настроить их параметры по наблюдениям. В отличие от подобных задач из других областей, рассматриваемая в работе задача характеризуется существенной неопределенностью в доступных оперативных данных, а сама модель очень чувствительна к начальным условиям. В этих условиях, предлагаемый в работе подход позволяет получить оценки параметров моделей в виде их распределений, которые вычисляются с достаточно высокой точностью в результате решения строго поставленной оптимизационной задачи. Кроме этого, моделирование неопределенности в данных с помощью аддитивного в каждой точке шума со своим распределением, повышает гибкость модели и позволяет осуществить его фильтрацию при прогнозировании.

### Литература

1. Попков Ю.С., Дубнов Ю.А., Попков А.Ю. Прогнозирование развития эпидемии COVID-19 в странах Европейского союза с использованием энтропийно-рандомизированного подхода // Информатика и автоматизация, 2021, Т. 20, № 5, с. 1010-1033, <https://doi.org/10.15622/ia.20.5.1>.
2. van den Driessche P. *Mathematical Epidemiology* / ed. by Brauer F., van den Driessche P., Wu J. Berlin, Heidelberg: Springer Berlin Heidelberg, 2008. Vol. 1945 of *Lecture Notes in Mathematics*. P. 147–157. <https://doi.org/10.1007/978-3-540-78911-6>.
3. Айвазян С.А., Мхитарян В.С. *Прикладная статистика и основы эконометрики*. — М.: Юнити, 1998.
4. Лагутин М.Б. *Наглядная математическая статистика*. — Бинوم. Лаб. знаний, 2013.
5. Боровков А.А. *Математическая статистика*. — М.: Наука, 1984.
6. Bishop C. *Pattern Recognition and Machine Learning (Information Science and Statistics)*, 2006. Springer, New York, 2006.
7. Hastie T., Tibshirani R., Friedman J. *The Elements of Statistical Learning: Data mining, Inference, and Prediction*. Springer New York, 2009.
8. Мерков А.Б. *Распознавание образов. Введение в методы статистического обучения*. М. : URSS, 2010.
9. Попков Ю.С., Попков А.Ю., Дубнов Ю.А. *Рандомизированное машинное обучение при ограниченных наборах данных: от эмпирической вероятности к энтропийной рандомизации*. — М.: ЛЕНАНД, 2019. ISBN: 978-5-9710-5908-0.
10. Попков Ю.С., Дубнов Ю.А. *Энтропийно-робастное рандомизированное прогнозирование при малых объемах ретроспективных данных // Автоматика и телемеханика*. 2016. № 5. С. 109–127.
11. Попков А.Ю. *Рандомизированное машинное обучение нелинейных моделей с применением к прогнозированию развития эпидемического процесса // Автоматика и телемеханика*. 2021. № 6. С. 149–168. <https://doi.org/10.31857/S0005231021060064>.
12. Popkov Y.S., Dubnov Y.A., Popkov A.Y. *Introduction to the Theory of Randomized Machine Learning // Learning Systems: From Theory to Practice* / ed. by Sgurev V., Piuri

- V., Jotsov V. Cham: Springer International Publishing, 2018. P. 199–220. ISBN: 978-3-319-75181-8. [https://doi.org/10.1007/978-3-319-75181-8\\_10](https://doi.org/10.1007/978-3-319-75181-8_10).
13. Попков Ю.С., Попков А.Ю., Дубнов Ю.А. Элементы рандомизированного прогнозирования и его применение для предсказания суточной электрической нагрузки энергетической системы // Автоматика и телемеханика. 2020. С. 148–172. <https://doi.org/10.1134/S0005231019070107>.
  14. Kermack W.O., McKendrick A.G. Contributions to the Mathematical Theory of Epidemics // Proceedings of the Royal Society. 1927. Vol. 115A. P. 700–721.
  15. Müller G.R. Zeitschrift für allgemeine Mikrobiologie / In: The Population Dynamics of Infectious Diseases: Theory and Applications. 368 S., 135 Abb., 104 Tab. London-New York, Chapman and Hall, 1984, Vol. 24, no. 2. pp. 76–76. <https://doi.org/10.1002/jobm.19840240203>.
  16. Hethcote H.W. Three Basic Epidemiological Models // Applied Mathematical Ecology. Springer Berlin Heidelberg, 1989. pp. 119–144. [https://doi.org/10.1007/978-3-642-61317-3\\_5](https://doi.org/10.1007/978-3-642-61317-3_5).
  17. Peng L., Yang W., Zhang D., Zhuge C., Hong L. Epidemic analysis of COVID-19 in China by dynamical modeling // arXiv, 2020. 10.48550/ARXIV.2002.06563.
  18. Yang W., Zhang D., Peng L., Zhuge C., Hong L. Rational evaluation of various epidemic models based on the COVID-19 data of China // Epidemics, 2021. Vol. 37. p. 100501. <https://doi.org/10.1016/j.epidem.2021.100501>.
  19. Cheng C., Zhang D., Dang D., Geng J., Zhu P., Yuan M., Liang R., Yang H., Jin Y., Xie J., Chen S., Duan G. The incubation period of COVID-19: a global meta-analysis of 53 studies and a Chinese observation study of 11 545 patients // Infectious Diseases of Poverty, 2021. Vol. 10, no. 1. <https://doi.org/10.1186/s40249-021-00901-9>.
  20. Huang S., Li J., Dai C., Tie Z., Xu J., Xiong X., Hao X., Wang Z., Lu C. Incubation period of coronavirus disease 2019: New implications for intervention and control // International Journal of Environmental Health Research, 2021. P. 1–9. <https://doi.org/10.1080/09603123.2021.1905781>.
  21. Li Q. et al. Early Transmission Dynamics in Wuhan, China, of Novel Coronavirus — Infected Pneumonia // New England Journal of Medicine, 2020. Vol. 382, no. 13. P. 1199–1207. <https://doi.org/10.1056/nejmoa2001316>.
  22. Nie X. et al. Epidemiological Characteristics and Incubation Period of 7015 Confirmed Cases With Coronavirus Disease 2019 Outside Hubei Province in China // The Journal of Infectious Diseases, 2020. Vol. 222, no. 1. pp. 26–33. <https://doi.org/10.1093/infdis/jiaa211>.
  23. Guidotti E., Ardia D. COVID-19 Data Hub // Journal of Open Source Software. 2020. Vol. 5, no. 51. P. 2376. <https://doi.org/10.21105/joss.02376>.
  24. COVID-19 Data Hub. <https://www.covid19datahub.io>. 2021. Accessed: 2022-06-20.
  25. Флах П. Наука и искусство построения алгоритмов, которые извлекают знания из данных. ДМК Пресс, 2015.
  26. Rubinstein R.Y., Kroese D.P. Simulation and the Monte Carlo method. John Wiley & Sons, 2007. Vol. 707.

**Попков Алексей Юрьевич** — канд. техн. наук, ведущий научный сотрудник, Федеральный исследовательский центр "Информатика и управление" Российской академии наук. Область научных интересов: энтропийные методы, рандомизированное машинное обучение, интеллектуальный анализ данных, разработка программного обеспечения. Число научных публикаций — 48. [aporkov@isa.ru](mailto:aporkov@isa.ru); улица Вавилова, 44-2, 119133, Москва, Россия; р.т.: +7(499)135-6260.

**Дубнов Юрий Андреевич** — научный сотрудник, Федеральный исследовательский центр «Информатика и управление» Российской академии наук. Область научных интересов: машинное обучение, байесовское оценивание. Число научных публикаций — 32. yury.dubnov@phystech.edu; улица Вавилова, 44-2, 119133, Москва, Россия; р.т.: +7(499)135-6260.

**Попков Юрий Соломонович** — академик РАН, главный научный сотрудник, Федеральный исследовательский центр «Информатика и управление» Российской академии наук. Область научных интересов: энтропийные методы, макросистемы, рандомизированное машинное обучение. Число научных публикаций — 224. popkov@isa.ru; улица Вавилова, 44-2, 119133, Москва, Россия; р.т.: +7(499)135-6260.

**Поддержка исследований.** Работа выполнена при финансовой поддержке Российского фонда фундаментальных исследований (проекты 20-07-00683, 20-04-60119).

A. POPKOV , Yu. DUBNOV , Yu. POPKOV  
**RANDOMIZED MACHINE LEARNING AND FORECASTING OF  
NONLINEAR DYNAMIC MODELS APPLIED TO SIR  
EPIDEMIOLOGICAL MODEL**

*Popkov A., Dubnov Yu., Popkov Yu. Randomized Machine Learning and Forecasting of Nonlinear Dynamic Models Applied to SIR Epidemiological Model.*

**Abstract.** We propose an approach to the estimation of the parameters of non-linear dynamic models using the concept of Randomized Machine Learning (RML), based on the transition from deterministic models to random ones (with random parameters), followed by estimation of the probability distributions of parameters and noises on real data. The main feature of this method is its efficiency in conditions of a small amount of real data. The paper considers models formulated in terms of ordinary differential equations, which are converted to a discrete form for setting and solving the problem of entropy optimization. The application of the proposed approach is demonstrated on the problem of predicting the total number of infected COVID-19 using a dynamic SIR epidemiological model. To do this, we construct a randomized SIR model (R-SIR) with one parameter, the entropy-optimal estimate of which is realized by its probability density function, as well as the probability density functions of the measurement noise at the points where training is performed. Next, the technique of randomized prediction with noise filtering is applied, based on the generation of the corresponding distributions and the construction of an ensemble of predictive trajectories with the calculation of the trajectory averaged over the ensemble. The paper implements a computational experiment using real operational data on the infection cases in the form of a comparative study with a well-known method for estimating model parameters based on the least squares method. The results obtained in the experiment demonstrate a significant decrease in the mean absolute percentage error (MAPE) with respect to real observations in the forecast interval, which shows the efficiency of the proposed method and its effectiveness in problems of the type considered in the work.

**Keywords:** randomized machine learning, entropy, entropy estimation, forecasting, randomized forecasting.

## References

1. Popkov Y.S., Dubnov Y.A., Popkov A.Y. Forecasting Development of COVID-19 Epidemic in European Union Using Entropy-Randomized Approach // Informatics and Automation, 2021, Vol. 20, No. 5, pp. 1010-1033, <https://doi.org/10.15622/ia.20.5.1>.
2. van den Driessche P. Mathematical Epidemiology / ed. by Brauer F., van den Driessche P., Wu J. Berlin, Heidelberg: Springer Berlin Heidelberg, 2008. Vol. 1945 of Lecture Notes in Mathematics. P. 147–157. <https://doi.org/10.1007/978-3-540-78911-6>.
3. Aivazyan S.A., Mhitaryan V.S. Prikladnaya statistika i osnovy ekonometriki. — Moscow, Unity, 1998.
4. Lagutin M.B. Naglyadnaya matematicheskaya statistika. — Binom, 2013.
5. Borovkov A.A. Matematicheskaya statistika. — Moscow, Nauka, 1984.
6. Bishop C. Pattern Recognition and Machine Learning (Information Science and Statistics), 2006. Springer, New York, 2006.
7. Hastie T., Tibshirani R., Friedman J. The Elements of Statistical Learning: Data mining, Inference, and Prediction. Springer New York, 2009.

8. Merkov A.B. *Raspoznavanie obrazov. Vvedenie v metody statisticheskogo obucheniya.* Moscow, URSS, 2010.
9. Popkov Y.S., Popkov A.Y., Dubnov Y.A. *Randomizirovannoe mashinnoe obuchenie pri ogranichennykh naborakh dannykh: ot empiricheskoy veroyatnosti k entropiynoy randomizatsii.* Moscow: LENAND, 2019. ISBN: 978-5-9710-5908-0.
10. Popkov, Y.S., Dubnov, Y.A. Entropy-robust randomized forecasting under small sets of retrospective data. *Automation and Remote Control.* 2016. Vol. 77, pp. 839–854. <https://doi.org/10.1134/S0005117916050076>.
11. Popkov A.Y. *Randomized Machine Learning of Nonlinear Models with Application to Forecasting the Development of an Epidemic Process* // *Automation and Remote Control.* 2021. Vol. 82, pp. 1049–1064. <https://doi.org/10.1134/S0005117921060060>.
12. Popkov Y.S., Dubnov Y.A., Popkov A.Y. *Introduction to the Theory of Randomized Machine Learning* // *Learning Systems: From Theory to Practice* / ed. by Sgurev V., Piuri V., Jotsov V. Cham: Springer International Publishing, 2018. P. 199–220. ISBN: 978-3-319-75181-8. [https://doi.org/10.1007/978-3-319-75181-8\\_10](https://doi.org/10.1007/978-3-319-75181-8_10).
13. Popkov Y., Popkov A., Dubnov Y. *Elements of Randomized Forecasting and Its Application to Daily Electrical Load Prediction in a Regional Power System* // *Automation and Remote Control.* 2020. Vol. 81, pp. 1286–1306. <https://doi.org/10.1134/S0005117920070103>.
14. Kermack W.O., McKendrick A.G. *Contributions to the Mathematical Theory of Epidemics* // *Proceedings of the Royal Society.* 1927. Vol. 115A. P. 700–721.
15. Müller G.R. *Zeitschrift für allgemeine Mikrobiologie* / In: *The Population Dynamics of Infectious Diseases: Theory and Applications.* 368 S., 135 Abb., 104 Tab. London-New York, Chapman and Hall, 1984, Vol. 24, no. 2. pp. 76–76. <https://doi.org/10.1002/jobm.19840240203>.
16. Hethcote H.W. *Three Basic Epidemiological Models* // *Applied Mathematical Ecology.* Springer Berlin Heidelberg, 1989. pp. 119–144. [https://doi.org/10.1007/978-3-642-61317-3\\_5](https://doi.org/10.1007/978-3-642-61317-3_5).
17. Peng L., Yang W., Zhang D., Zhuge C., Hong L. *Epidemic analysis of COVID-19 in China by dynamical modeling* // arXiv, 2020. 10.48550/ARXIV.2002.06563.
18. Yang W., Zhang D., Peng L., Zhuge C., Hong L. *Rational evaluation of various epidemic models based on the COVID-19 data of China* // *Epidemics,* 2021. Vol. 37. p. 100501. <https://doi.org/10.1016/j.epidem.2021.100501>.
19. Cheng C., Zhang D., Dang D., Geng J., Zhu P., Yuan M., Liang R., Yang H., Jin Y., Xie J., Chen S., Duan G. *The incubation period of COVID-19: a global meta-analysis of 53 studies and a Chinese observation study of 11 545 patients* // *Infectious Diseases of Poverty,* 2021. Vol. 10, no. 1. <https://doi.org/10.1186/s40249-021-00901-9>.
20. Huang S., Li J., Dai C., Tie Z., Xu J., Xiong X., Hao X., Wang Z., Lu C. *Incubation period of coronavirus disease 2019: New implications for intervention and control* // *International Journal of Environmental Health Research,* 2021. P. 1–9. <https://doi.org/10.1080/09603123.2021.1905781>.
21. Li Q. et al. *Early Transmission Dynamics in Wuhan, China, of Novel Coronavirus — Infected Pneumonia* // *New England Journal of Medicine,* 2020. Vol. 382, no. 13. P. 1199–1207. <https://doi.org/10.1056/nejmoa2001316>.
22. Nie X. et al. *Epidemiological Characteristics and Incubation Period of 7015 Confirmed Cases With Coronavirus Disease 2019 Outside Hubei Province in China* // *The Journal of Infectious Diseases,* 2020. Vol. 222, no. 1. pp. 26–33. <https://doi.org/10.1093/infdis/jiaa211>.
23. Guidotti E., Ardia D. *COVID-19 Data Hub* // *Journal of Open Source Software.* 2020. Vol. 5, no. 51. P. 2376. <https://doi.org/10.21105/joss.02376>.

24. COVID-19 Data Hub. <https://www.covid19datahub.io>. 2021. Accessed: 2022-06-20.
25. Flach P. *Nauka i iskusstvo postroeniya algoritmov, kotorie izvlekaiut znania iz dannyykh*. Moscow, DMK Press, 2015.
26. Rubinstein R. Y., Kroese D.P. *Simulation and the Monte Carlo method*. John Wiley & Sons, 2007. Vol. 707.

**Popkov Alexey** — Ph.D., Leading researcher, Federal Research Center “Computer Science and Control” of Russian Academy of Sciences. Research interests: entropy methods, machine learning, data mining, software development. The number of publications — 48. [apopkov@isa.ru](mailto:apopkov@isa.ru); 44-2, Vavilov St., 119133, Moscow, Russia; office phone: +7(499)135-6260.

**Dubnov Yuri** — Researcher, Federal Research Center “Computer Science and Control” of Russian Academy of Sciences. Research interests: machine learning, bayessian estimation. The number of publications — 32. [yury.dubnov@phystech.edu](mailto:yury.dubnov@phystech.edu); 44-2, Vavilov St., 119133, Moscow, Russia; office phone: +7(499)135-6260.

**Popkov Yuri** — Academician of Russian Academy of Sciences, Chief researcher, Federal Research Center “Computer Science and Control” of Russian Academy of Sciences. Research interests: entropy, macrosystems, randomized machine learning, optimization. The number of publications — 224. [popkov@isa.ru](mailto:popkov@isa.ru); 44-2, Vavilov St., 119133, Moscow, Russia; office phone: +7(499)135-6260.

**Acknowledgements.** This work was supported by Russian Foundation for Basic Research (projects 20-07-00683, 20-04-60119).



И.С. КИПЯТКОВА, И.А. КАГИРОВ  
**АНАЛИТИЧЕСКИЙ ОБЗОР МЕТОДОВ РЕШЕНИЯ  
ПРОБЛЕМЫ МАЛЫХ НАБОРОВ ДАННЫХ ПРИ СОЗДАНИИ  
СИСТЕМ АВТОМАТИЧЕСКОГО РАСПОЗНАВАНИЯ РЕЧИ  
ДЛЯ МАЛОРЕСУРСНЫХ ЯЗЫКОВ**

*Кипяткова И.С., Кагиров И.А. Аналитический обзор методов решения проблемы малых наборов данных при создании систем автоматического распознавания речи для малоресурсных языков.*

**Аннотация.** В статье рассматриваются основные методы решения проблемы малых наборов обучающих данных для создания автоматических систем распознавания речи для так называемых малоресурсных языков. Рассматривается понятие малоресурсных языков и формулируется рабочая дефиниция на основании ряда работ по этой тематике. Определены основные трудности, связанные с применением классических схем автоматического распознавания речи к материалу малоресурсных языков, и очерчен круг основных методов, использующихся для решения обозначенных проблем. В статье подробно рассматриваются методы аугментации данных, переноса знаний и сбора речевого материала. В зависимости от конкретной задачи, выделяются методы аугментации аудиоматериала и текстовых данных, переноса знаний и мультизадачного обучения. Отдельный раздел статьи посвящен существующему информационному обеспечению, базам данных и основным принципам их организации с точки зрения работы с малоресурсными языками. Делаются выводы об оправданности методов аугментации данных и переноса знаний для языков с минимальным информационным обеспечением. В случае полного отсутствия данных для конкретного языка и родительских моделей структурно схожих языков предпочтительным вариантом является сбор новой базы данных, в том числе, при помощи краудсорсинга. Многозадачные модели переноса знаний оказываются эффективными в том случае, если исследователь располагает большими наборами данных. Если доступны данные по языку с достаточными ресурсами, предпочтительной является работа с языковой парой. Сделанные в результате данного обзора выводы в дальнейшем предполагается применить при работе с малоресурсным карельским языком, для которого авторы статьи создают систему автоматического распознавания речи.

**Ключевые слова:** малоресурсные языки, аугментация речевых данных, перенос знаний, машинное обучение, языковые корпуса.

**1. Введение.** Существующие в настоящее время системы автоматической обработки естественных языков (расознавания речи, анализа тональности, автоматического перевода) построены при помощи технологий машинного обучения, требующих большого количества данных для эффективной работы. Однако языков с достаточной степенью изученности и готовыми большими наборами данных сравнительно мало. По разным оценкам, в мире насчитывается от 5 до 7 тысяч языков, и языками с достаточными ресурсами могут быть признаны только около 20 из них [1, 2]. Большинство языков мира описаны и документированы недостаточно хорошо; более того,

данные по ним часто недоступны. Такие языки принято называть малоресурсными, и применение к ним современных методов обработки естественных языков зачастую невозможно. Осознание актуальности этой проблемы неоднократно находило отражение в научных публикациях [3, 4].

В настоящей статье содержится обзор основных методов, связанных с применением речевых технологий в контексте малоресурсных языков. Из-за специфики темы в фокусе данной статьи оказываются как информационное обеспечение малоресурсных языков, то есть наборы данных, так методика их создания. Целью настоящей статьи является систематизация основных методов получения и подготовки данных для применений в системах распознавания речи (и шире – автоматической обработки естественных языков) для малоресурсных языков. В статье выполнено выделение основных методов, применяемых для решения проблемы малых и/или недостаточных наборов данных для малоресурсных языков, представлена классификация методов по типам задач, для которых они применяются, проведен их сравнительный анализ. Кроме того, в статье подробно рассматривается понятие малоресурсного языка, которое является ключевым для определения набора методов, пригодных для работы с конкретным языковым материалом.

Статья имеет следующую структуру: после настоящего Введения дается краткое определение малоресурсных языков. Далее приводится общий обзор проектов и наборов данных, связанных с малоресурсными языками. Следующие разделы посвящены основным подходам к малоресурсным языкам, в том числе методам сбора данных, аугментации данных и переноса знаний при обучении моделей. Наконец, в Заключении делаются выводы о положении вещей в рассматриваемой области.

**2. Малоресурсные языки: определение и проблемы автоматической обработки.** В современной традиции обработки естественных языков под термином «малоресурсные языки» понимаются языки с малым объемом электронных ресурсов, доступных для обработки. Впервые термин «малоресурсные языки» (англ. low-resource languages, under-resourced languages) был предложен в работах [5, 6]. Одновременно был выдвинут ряд критериев, на основании которых тот или иной язык может быть отнесен к малоресурсным: наличие письменности, доступность языковых материалов в сети Интернет, существование лингвистических описаний языка, электронных (двуязычных) словарей и параллельных корпусов и т.п. В этих же работах были предложены системы оценки

доступности ресурсов для конкретного языка, основанные на вычислении среднего значения коэффициентов, присваиваемых каждому ресурсу.

В более поздних работах [7, 8] содержание термина «малоресурсные языки» было еще расширено: учитываются такие факторы, как низкий социальный статус языка и его малоизученность. Тем не менее, на практике [9] основным критерием для отнесения какого-либо языка к малоресурсным является низкий для решения конкретной задачи объем электронных языковых данных, которым располагают исследователи.

Обыкновенно существует прямая взаимосвязь между собственно уровнем развития информационных технологий для языка и степенью лингвистической изученности языкового материала. Кроме того, чаще всего малоресурсными оказываются миноритарные и вымирающие языки [10]. Следует подчеркнуть, что описанная ситуация является типичной, но не обязательной; так, ряд хорошо изученных языков, имеющих официальный статус, может быть отнесен к малоресурсным (казахский или белорусский), в то время как некоторые миноритарные языки таковыми не являются (баскский язык).

Малоресурсные языки, как и любые естественные языки, представляют большой интерес не только для лингвистов. В статье [8] отмечается, что только в Африке и в Индии существует около 2 тысяч малоресурсных языков, на которых разговаривают порядка 2,5 миллиарда человек. Создание инструментов для естественной коммуникации с носителями этих языков может помочь в решении ряда проблем экономического, культурного и экологического характера.

Низкий уровень развития речевых технологий для малоресурсных языков объясняется рядом причин. В первую очередь, задача документации и формализации структур малоизученного языка сама по себе достаточно трудоемка с научной точки зрения. Кроме того, она сопряжена с высокими финансовыми затратами на подготовку необходимых инструментов (речевых корпусов, программного обеспечения). Также важно то, что существующие на сегодня способы моделирования и создания комплексов распознавания речи направлены на решение узкого круга задач и не учитывают особенности работы с малоресурсными языками.

Проблемам малоресурсных языков, созданию наборов данных и адаптации моделей для автоматической обработки малоресурсных языков посвящен ряд конференций и семинаров. В первую очередь,

это International Workshop on Spoken Language Technologies for Under-resourced Languages (SLTU), Collaboration and Computing for Under-Resourced Languages (CCURL), Language Resources (LRs) and Evaluation for Language Technologies (LREC), также тематика малоресурсных языков часто фигурирует в повестке других мероприятий, посвященных автоматической обработке естественных языков (Association for Computational Linguistics (ACL) European Chapter of the Association for Computational Linguistics (EACL) и т.п.).

В России существует свыше 150 языков\*, многие из которых являются малоресурсными и не имеют собственных корпусов. Тем не менее, за последние годы появляются работы, в которых предлагаются методы и системы для автоматической обработки этих языков, предпринимаются попытки создания корпусов. В качестве примера можно привести работы [11] (татарский язык), [12] (чеченский язык), [13] (вепский и карельский языки).

**3. Проблемы автоматической обработки малоресурсных языков и основные методы их решения.** Для удобства читателя на рисунке 1 представлена общая архитектура системы автоматического распознавания слитной речи. Применение подобных архитектур к материалу малоресурсных языков обнаруживает ряд проблем на различных этапах распознавания, отраженных на схеме.

Как правило, к основным компонентам подобных систем распознавания речи относятся акустическая, лексическая и языковая модели. Для обучения акустических моделей необходим речевой корпус, для обучения модели языка – текстовый. Кроме того, необходимо создать транскрипции для слов, которые будут использоваться в системе. Стоит отметить, что в настоящее время развивается интегральный (англ. end-to-end) подход к построению систем распознавания речи, который заключается в том, что только одна модель генерирует необходимые выходные данные без использования других компонентов [14].

Как было отмечено в самом начале этой статьи, традиционные подходы к автоматической обработке естественного языка требуют больших объемов обучающих данных, однако для малоресурсных языков такой объем данных недоступен. Недоступность данных и знаний по языку – это комплексная проблема, она актуальна для всех уровней обработки языка: собственно фонетического, лексического и грамматического [15]. Особенно остро проблема недостаточного объема обучающих данных стала проявляться с развитием

---

\* Ethnologue: Languages of the World. Russian Federation. URL: <https://www.ethnologue.com/country/RU/languages> (дата обращения: 22.06.2022.)

искусственных нейронных сетей (ИНС), которые позволяют повысить точность автоматического распознавания речи по сравнению с другими подходами (в частности, скрытыми марковскими моделями для акустического моделирования, и  $n$ -граммами – для языкового), однако требуют большой объем обучающих данных, поэтому в данной статье главным образом приведены методы, применяемые для обучения нейросетевых моделей. Однако также описываются методы аугментации (увеличения объема) данных, которые могут использоваться и для обучения систем, построенных не на нейронных сетях.

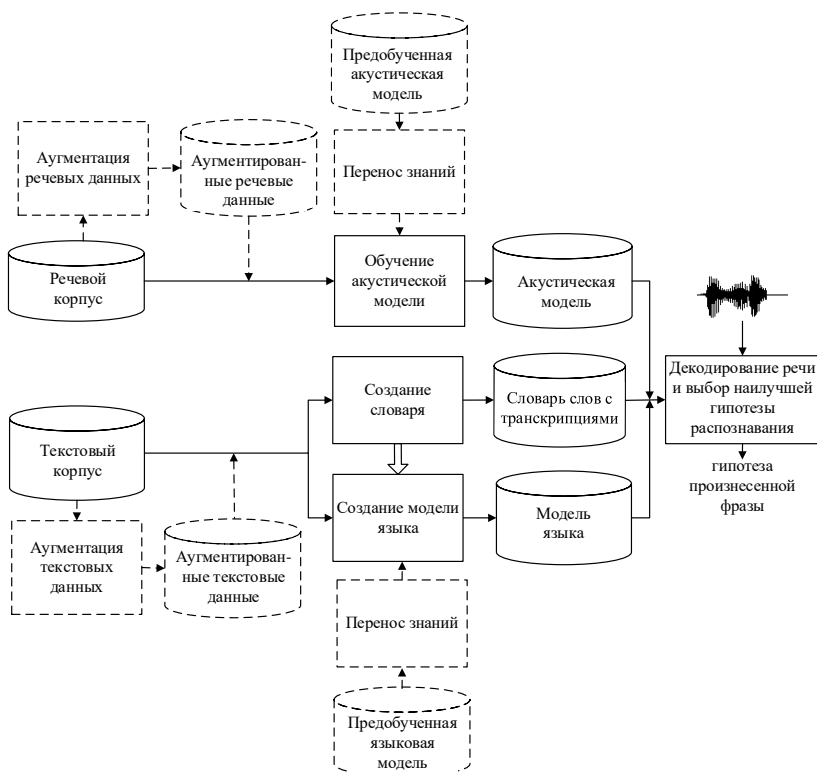


Рис. 1. Общая архитектура системы автоматического распознавания слитной речи

На рисунке пунктирной линией отмечены модули, которые могут входить в состав системы распознавания речи для малоресурсных языков:

- 1) аугментация данных (аудиоданные, текстовые данные);
- 2) перенос знаний (в том числе многозадачное обучение).

Строго говоря, еще одним эффективным инструментом получения обучающих данных является сбор собственного корпуса, однако этот метод требует больших временных, человеческих и зачастую финансовых затрат.

Также следует отметить, что при работе с малоресурсными языками исследователю приходится решать ряд других, специфических для этой области проблем (нестандартная письменность или ее отсутствие, типологическая уникальность фонетических кластеров, создание словаря транскрипций и т.п.), однако данный обзор ограничивается только проблемой малого объема данных, поскольку она является основной для всех малоресурсных языков. Последующие разделы будут посвящены методам решения этой проблемы.

#### **4. Методы сбора и транскрибирования речевых данных.**

Самым надежным способом получения языковых данных для любого естественного языка является запись собственного корпуса. Сбор таких корпусов представляет собой задачу, сопряженную с рядом трудностей (географическая удаленность, доступность дикторов и текстов, социальные проблемы). За последние годы был собран достаточно большой массив данных по малоресурсным языкам, однако общее количество таких корпусов оценивается в несколько десятков [16].

Одним из способов сбора и разметки данных для обучения моделей является краудсорсинг, при этом можно выделить три типа краудсорсинга [17]: 1) наемный труд, к которому привлекаемые люди получают оплату за свою работу; 2) игры с целью (англ. games with a purpose; GWAP), где задача представлена как игра; 3) привлечение волонтеров.

В работе [18] авторы описывают созданное ими приложение для сбора речевых данных путем краудсорсинга. Приложение имеет клиент-серверную архитектуру. Клиентское приложение ставится на смартфоны под управлением операционной системы Андроид. Клиентское приложение связывается с сервером, пользователь читает предложения, которые показываются ему на экране, по окончании записи речевые данные отправляются на сервер.

Среди крупнейших проектов по сбору данных малоресурсных языков стоит назвать такие, как GlobalPhone, LORELEI, REFLEX-LCTL и IARPA BABEL.

Корпус GlobalPhone [19] – это многоязычный (20 языков) корпус данных, разработанный в сотрудничестве с Технологическим институтом Карлсруэ (KIT). Полный корпус данных включает: 1) аудио/речевые данные, т. е. высококачественные записи устных высказываний, прочитанных носителями языка; 2) соответствующие транскрипции; 3) словари произношения, охватывающие словарный запас расшифровок; 4) базовые n-граммные языковые модели. Первые два называются базой данных речи и текста GlobalPhone (GP-ST), третий – словарями GlobalPhone (GP-Dict), а последний – языковыми моделями GlobalPhone (GP-LM). Весь корпус GlobalPhone представляет собой многоязычную базу данных расшифрованной речи на уровне слов для разработки и оценки систем обработки речи с большим словарем на самых распространенных языках мира. Корпус GlobalPhone создан единообразно для всех включенных в нее языков в плане объема текста и речи для каждого языка (100 дикторов на язык), качества записей и аннотаций.

В проекте LORELEI (Low Resource Languages for Emergent Incidents) [20], созданном Консорциумом языковых данных, представлены 35 языков; языки делятся на репрезентативные (23) и прочие (12). Репрезентативные языки используются для обеспечения широкого типологического охвата, а оставшиеся 12 языков были выбраны для обеспечения разработки и тестирования возможностей системы. В LORELEI языки организованы в так называемые «репрезентативные языковые пакеты», интегрированные в общую систему аннотаций. Репрезентативный языковой пакет для LORELEI содержит одноязычный текст, параллельный текст, несколько типов аннотаций, инструменты для обработки текста, сегментации и маркировки языковых единиц, а также словари и грамматические правила. Языковые пакеты LORELEI были собраны специально в рамках предметной темы «ситуационная осведомленность в непредвиденных ситуациях», что обеспечивает проекту определенную социальную значимость.

Проект REFLEX-LCTL (Research on English and Foreign Language Exploitation-Less Commonly Taught Languages) [21], спонсируемый правительством Соединенных Штатов, представлял собой другую попытку создания базовых языковых ресурсов для нескольких малоресурсных языков. В рамках этого проекта были созданы языковые пакеты для 19 языков. Этот подход сходен с

подходом, предложенным в LORELEI, однако, в отличие от LORELEI, пакеты языковых данных не объединены в рамках общей системы аннотаций.

Одним из крупнейших проектов по сбору языковых данных является IARPA BABEL<sup>†</sup> – проект, в котором приняли участие исследователи из различных стран Европы. Результатом проекта BABEL является многоязычная база данных, включающая транскрибированные записи речи на нескольких десятках малоресурсных разноструктурных языков из различных географических ареалов. Как утверждают сами создатели базы данных, основной целью проекта является разработка технологий распознавания речи для широкого спектра языков, в частности, методов моделирования малоресурсных языков в условиях малых наборов обучающих данных и их низкого качества (шумы, несбалансированность данных).

Следующим этапом после записи речевых данных является их транскрибирование, поскольку для обучения акустических моделей необходимо иметь расшифровку речевых записей в текстовом виде. Для малоресурсных языков транскрибирование речевых данных может выполняться путем краудсорсинга, при котором для разметки данных привлекают людей, не говорящих на языке, речевые данные которого необходимо транскрибировать, при этом люди записывают то, что они слышат, как звуки собственного языка. Получаемая таким образом транскрипция, называемая «несоответствующей» (англ. "mismatched"), преобразуется затем в транскрипцию для целевого языка, называемую вероятностной транскрипцией. Такой подход к транскрибированию был исследован в работе [22] для вьетнамского языка, при этом «несоответствующие» транскрипции были сделаны носителями путунхуа. Также в работе было исследовано совместное использование «соответствующих» и «несоответствующих» транскрипций и было показано, что использование «несоответствующих» транскрипций может повысить точность распознавания при недостатке «соответствующих» транскрипций.

Также применение вероятностных транскрипций исследовалось и в работе [23]. Транскрипции создавались следующим образом: 1) самообучение (система распознавания речи, предобученная на других языках, использовалась для транскрибирования данных целевого языка); 2) "mismatched" краудсорсинг; 3) использование электроэнцефалограммы (ЭЭГ): суть метода состоит в том, что

---

<sup>†</sup> BABEL // Intelligence Advanced Research Projects Activity. URL: <https://www.iarpa.gov/research-programs/babel> (дата обращения: 22.06.2022.)



вначале, пока человек слушает речь на родном ему языке, записывается его ЭЭГ, выполняется обучение классификаторов признаков на размеченных по типам (например, фрикативный, сонорный) фонах. Затем человек слушает речь на целевом языке, и результаты его ЭЭГ используются для оценки распределения вероятности по набору фонов целевого языка.

**5. Аугментация обучающих данных.** Аугментация данных – это набор методов, которые используются для создания дополнительных данных либо путем модификации существующих данных, либо путем добавления данных из сторонних источников для использования при обучении модели.

**5.1. Аугментация речевых данных.** Аугментация речевых данных может проводиться путем изменения высоты голоса, темпа речи, громкости речи, наложения шума, модификации признаков, извлеченных из речевого сигнала, а также синтеза речи [24]. Аугментация данных путем изменения речевого сигнала описана в работе [25], где было предложено выполнить изменение темпа речи путем умножения исходной скорости на коэффициенты 0,9, 1,0 и 1,1, что позволило снизить количество неправильно распознанных слов (англ. word error rate; WER) на 2% для путунхуа. Аугментация путем добавления к речевым признакам случайных значений была выполнена в работе [26]. Кроме того, может быть выполнена аугментация не самого речевого сигнала, а его спектрограммы, подобный подход был применен в работе [27] для интегрального распознавания речи.

В некоторых работах применяется сразу несколько типов аугментации. В частности, в работе [28] предложена двухступенчатая аугментация речевых данных. На первом этапе для повышения робастности акустических моделей к исходным речевым данным был добавлен случайный шум, а также выполнено изменение темпа речи. На втором этапе происходит аугментация признаков, полученных путем адаптации к голосу диктора.

Также для аугментации может использоваться технология преобразования голоса (англ. voice conversion), которая состоит в модификации исходной аудиозаписи голоса диктора в голос другого диктора (целевой голос) без изменения лексического содержания речи [29]. Чаще всего для этого используют генеративно-сопоставительные сети (англ. Generative Adversarial Network (GAN)) [30], а также их модификации, например, Wasserstein GAN, StarGAN. В работе [31] для непараллельного преобразования голоса предложен метод VAW-GAN, объединяющий условный вариационный автоэнкодер (англ. conditional

variational autoencoder; C-VAE) для моделирования акустических признаков речи от каждого диктора и Wasserstein GAN для синтеза голоса другого диктора. Архитектура StarGAN используется в работе [32], в которой описан метод преобразования речи, названный StarGAN-VC.

Несколько типов аугментации было применено в работе [33] для распознавания турецкой речи, в которой авторы исследовали такие виды аугментации, как изменения скорости речи, громкости, совместное изменение скорости и громкости, синтез речи (исследовалась система преобразования речи в текст от Google и интегральная система синтеза турецкой речи на основе сверточных глубоких сетей). Кроме того, были применены различные комбинации из описанных выше методов. Наилучший результат был получен при совместном применении всех методов, при этом снижение WER составило 14,8%.

Еще одним методом аугментации речевых данных является синтез речи. В большинстве современных работ для синтеза речи используется нейросетевая модель Tacatron 2 [34] от компании Google. В частности, такой метод аугментации был выполнен в работе [35] для синтеза детской речи на языке панджаби. Кроме того, в данной работе была выполнена аугментация за счет модификации формант в речевых записях корпуса взрослой речи. В работе [36] синтез речи использовался для аугментации речевых данных для разработки интегральной системы распознавания речи, что позволило существенно снизить WER, кроме того, был применен SpecAugment, что позволило получить дополнительное снижение WER. Недостатком такого метода аугментации является необходимость наличия речевых данных для обучения синтезатора речи, при их недостатке качество синтезируемой речи может быть неудовлетворительным. Так, авторы работы [37] не смогли получить увеличения точности распознавания при добавлении синтезированных данных к реальным при обучении акустических моделей, при этом авторы использовали статистический параметрический синтез речи. Также авторы выполнили синтез речи с помощью моделей Tacatron 2 и WGANSing (синтезатора, основанного на генеративных состязательных нейронных сетях), однако качество получившейся речи было настолько плохим, что авторы не стали проводить эксперименты с использованием этих данных. Плохое качество синтеза авторы объясняют недостатком данных для обучения.

**5.2. Аугментация текстовых данных.** Методы аугментации текстовых данных в контексте обработки естественных языков можно

разделить на две группы: с применением данных из других языков и без иноязычных данных.

**5.2.1. Аугментация на материале одного языка.** При сборе текстового материала для создания модели языка может возникнуть ситуация, когда текстового материала соответствующей предметной области мало, но есть текстовые данные для других предметных областей рассматриваемого языка. Особенно такая ситуация актуальна для малоресурсных языков. В этом случае можно обучить несколько моделей языка на текстах по каждой из имеющихся предметных областей, а затем выполнить их линейную интерполяцию, при этом коэффициент интерполяции подбирается так, чтобы получить минимальный коэффициент неопределенности (англ. perplexity) на отладочном текстовом корпусе [38].

В работе [39] выделены основные способы создания нейросетевой модели языка для заданной предметной области: 1) выбор данных из предметной области с большей вероятностью в ходе обучения (например, каждую эпоху использовать все данные предметной области и случайный поднабор остальных данных); 2) сортировка обучающих данных таким образом, чтобы данные непредметной области подавались на вход в начале обучения, а данные предметной области – в конце обучения, чтобы они имели большее влияние на модель; 3) обучение модели на данных непредметной области с последующей адаптацией модели к данным предметной области, например, посредством добавления к нейронной сети еще одного слоя и обучения его на данных предметной области, с предварительной фиксацией параметров остальных слоев; 4) большая часть параметров модели является общей для всех предметных областей, а некоторая часть параметров резервируется для конкретных предметных областей; таким образом, создается одна модель для различных предметных областей.

Распространенным методом текстовой аугментации является аугментация на основе замены слов или фраз, при которой данные расширяются за счет замены одних слов или словосочетаний синонимичными единицами. Типологически сходными методами аугментации является применение сокращений, использование векторных и контекстных представлений слов, однако эффективность их применения к материалу малоресурсных языков сильно ограничена наличием описаний и/или компьютерных моделей для конкретных языков [40].

В работе [41] исследуется аугментация текстовых данных на трех уровнях: символы (вставка/удаление/замена символа и

перестановка символов), слова (вставка/удаление/ перестановка слов, замена слова на синоним) и синтаксис. Самым сложным является синтаксический уровень, для работы с которым необходима разметка корпуса.

В работе [42] предложен метод аугментации размеченных текстовых данных, названный контекстной аугментацией, который состоит в том, что предварительно обученная языковая модель применяется для генерации замен слов в предложении на основе их контекста. В [42] в качестве такой модели использовалась двунаправленный рекуррентная ИНС. В работе [43] для контекстной аугментации данных использовались предварительно обученные модели на базе архитектуры трансформер: GPT-2, BERT и BART. Также аугментация путем замены слов была выполнена в работе [44] для адаптации модели к конкретной предметной области. В предложенном методе вначале выполняется обучение модели замены слов на основе двунаправленной сети с долгой кратковременной памятью (англ. Long Short-Term Memory; LSTM), аналогичной предложенной в работе [42], на размеченных исходных данных и данных заданной предметной области. Затем с использованием созданной модели выполняется преобразование предложений из текстового корпуса исходной предметной области в сеть спутывания (англ. confusion network), которая включает в себя возможные варианты последовательности слов для целевой предметной области. Затем с помощью модели языка на основе LSTM из сети спутывания выбираются предложения, которые, как подразумевается, являются грамматически корректными.

**5.2.2. Аугментация с привлечением иноязычных данных.** В том случае, если для конкретного малоресурсного языка существуют параллельные корпуса и/или системы машинного перевода, возможно применение методов аугментации с привлечением данных из другого языка. Простейшим методом является обратный перевод – процесс перевода одноязычного корпуса на целевой язык с помощью уже существующей системы машинного перевода с последующим обратным переводом на исходный язык. Затем полученные предложения исходного языка вместе с соответствующими предложениями целевого языка используются для построения искусственного (т.е. аугментированного) параллельного корпуса [45]. В некоторых случаях перевод с целевого языка на исходный осуществляется несколько раз (итеративный обратный перевод). Данные, полученные с использованием методики обратного перевода, обычно характеризуются большим количеством ошибок, чем

исходные параллельные данные, особенно если система машинного перевода, используемая для создания синтетических данных, несовершенна.

Основная трудность, сопряженная с этой методикой, состоит в том, что для ее осуществления необходимо наличие системы машинного перевода для данной языковой пары. В ряде работ отмечается, что эффективность обратного перевода зависит от многих факторов, таких как соотношение параллельных данных, а также структурное соответствие параллельных и одноязычных данных [48, 49]. Попытки использовать языковые данные языков с достаточными ресурсами также сильно зависят от родства внутри языковой пары [50] или наличия двуязычных словарей [51].

В том случае, когда два параллельных корпуса не представляют собой результат прямого перевода, но все же принадлежат к одной предметной области (хорошим примером являются статьи из Википедии на разных языках), их также можно использовать для аугментации данных. Основным инструментом в данном случае является векторное представление предложений и словосочетаний в текстах. Тем не менее, для малоресурсных языков этот метод не всегда применим либо в силу отсутствия собственно параллельных корпусов, либо из-за отсутствия адекватных языковых моделей для конкретных языковых пар.

В таблице 1 показано относительное снижение ошибки распознавание слов (WER), полученное различными исследователями за счет применение методов аугментации данных при обучении систем распознавания речи.

Наиболее эффективными методами аугментации аудиоданных могут быть признаны синтез речи и изменение спектрограммы. Несмотря на относительную простоту и низкие вычислительные затраты, аугментация при помощи изменения темпа речи и высоты голоса, а также добавление случайных значений к речевым признакам не обеспечивают значительного улучшения точности распознавания слов при применении в системах распознавания речи на малоресурсных языках.

Таблица 1. Результаты применения методов аугментации обучающих данных для обучения систем автоматического распознавания речи

| Методы аугментации | Изменяемые параметры                                     | Работы | Относительное сокращение ошибки распознавания слов (WER, %)            |
|--------------------|--|--------|--|
| Речевые данные     | высота голоса/ темп речи/<br>громкость речи              | [25]   | 2,00   |
|                    | добавление случайных значений к речевым признакам        | [26]   | 0,30   |
|                    | изменение спектрограммы                                  | [27]   | 27-46 (в зависимости от используемых данных и применения модели языка) |
|                    | преобразование голоса (voice conversion)                 | [46]   | 31,36  |
|                    | синтез речи  | [47]   | 60,40  |
| Текстовые данные   | использование текстовых данных другой предметной области | [39]   | 2,70 – 3,90 (в зависимости от объема данных)                           |

**6. Метод переноса знаний.** Метод переноса знаний (англ. transfer learning) — это метод обучения ИНС, когда знания нейросети, которая была обучена на одной задаче, переносятся на другую задачу. Этот метод используется в том случае, если обучающих данных для целевой задачи мало, но имеется большой обучающий корпус для другой смежной задачи.

Существует несколько подходов к выполнению переноса знаний, самым простым является адаптация существующей модели к новым данным [52], для чего могут использоваться методы максимального правдоподобия для нахождения параметров линейной регрессионной модели (англ. maximum likelihood linear regression (MLLR)) и адаптация с использованием апостериорного максимума (англ. maximum a posteriori (MAP)) [53]. Метод MLLR изначально был предложен для адаптации к голосу диктора, он позволяет выполнять адаптацию акустических моделей без повторного обучения параметров модели. MAP используется для адаптации к голосу диктора дикторонезависимых моделей по небольшому набору адаптационных данных. Так, например, в работе [54] методы MLLR и MAP

использовались для адаптации акустической модели, обученной на данных фламандских диалектов нидерландского языка, к близкородственному языку африкаанс. Также в данной работе исследовалось применение гетероскедастического линейного дискриминантного анализа (англ. heteroscedastic linear discriminant analysis (HLDA)) и адаптация к речи диктора.

Особую эффективность метод переноса знаний показал при обучении глубоких ИНС. С точки зрения систем распознавания речи, идея переноса знаний основана на том, что признаки, выделяемые при обучении нижними слоями ИНС, не зависят от языка, при этом специфичные для языка признаки выделяются верхними слоями ИНС. Обучение модели для малоресурсного языка с использованием метода переноса знаний выполняется в два этапа. Первым этапом является обучение родительской модели языка (англ. parent model) на большом наборе данных (нецелевых данных), которая впоследствии используется для инициализации весов в дочерней модели, обученной на материале малоресурсного языка (целевых данных). Очевидным преимуществом такого подхода является снятие проблемы малых данных для малоресурсного целевого языка. Родительская модель может быть обучена как на одном языке, так и на нескольких языках. Общая схема применения метода переноса знаний для обучения модели для малоресурсных языков показана на рисунке 2.

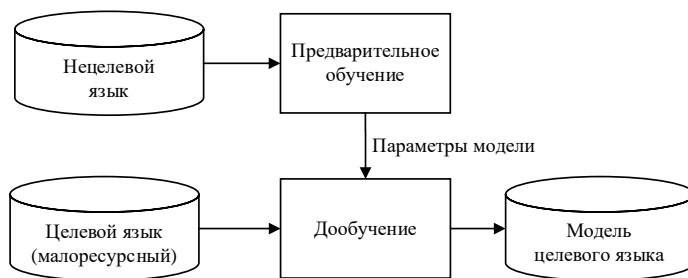


Рис. 2. Схема применения метода переноса знаний для обучения модели для малоресурсных языков

Метод переноса знаний был применен в работе [55] при обучении акустической модели для амхарского языка. В качестве нецелевых данных для предварительного обучения модели использовались речевые данные на английском и путунхуа. Применение метода переноса знаний позволило снизить WER с 38,72% до 24,50%.

В работе [56] применен метод переноса знаний для обучения системы распознавания речи для малоресурсного языка североамериканских индейцев сенека. Размер корпуса составлял всего 10 часов. К корпусу были применены три метода аугментации данных: 1) изменение скорости речи и частоты основного тона; 2) преобразование голоса с помощью метода StarGAN-VC; 3) преобразование голоса с помощью VAWGAN. Обучение нейросетевых акустических моделей происходило за 3 этапа. На первом этапе было выполнено предобучение модели на 960 часах английской речи из корпуса LibriSpeech. На втором этапе веса модели были проинициализированы значениями, полученными в ходе первого этапа обучения модели, и было произведено обучение модели на корпусе, включающем в себя 10 часов речи и аугментированные данные. На третьем этапе веса нейронной сети были проинициализированы значениями, полученными на втором этапе, и было выполнено обучение модели на исходных неаугментированных данных, чтобы исключить влияние артефактов аугментации.

В работе [57] исследуется влияние заморозки параметров нижних слоев ИНС при выполнении переноса знаний при обучении интегральной системы автоматического распознавания речи. Авторы обнаружили, что заморозка параметров нижних слоев позволяет повысить точность распознавания и скорость обучения. Существенное увеличение точности было получено при заморозке первого слоя, заморозка последующих слоев не привела к существенному увеличению точности распознавания.

Принцип переноса знаний может использоваться для создания многоязычных систем, в этом случае обычно применяется либо многоязычное смешивание (англ. *multilingual mix*), либо многозадачное обучение. При многоязычном смешивании выполняется обучение единой акустической модели для всех языков (обучение выполняется на всех имеющихся речевых данных) и используется единый набор фонем, включающий в себя все фонемы для всех языков (рисунок 3а). При декодировании речи для каждого языка используется эта единая акустическая модель и свой словарь произношений и модель языка. Многозадачное обучение состоит в обучении одной модели для разных задач. В контексте автоматического распознавания речи, в многозадачном обучении каждый язык рассматривается как задача. Таким образом, скрытые слои ИНС являются общими для всех языков, при этом модель имеет несколько выходных слоев – для каждой модели свой (рисунок 3б). Данные подходы к обучению многоязычной системе были применены,



в частности, в работах [58, 59], где также исследовался перенос знаний, при котором переносились веса скрытых слоев, а веса выходного слоя дообучались для каждого целевого языка на данных этого языка.




Рис. 3. Основные методы построения многоязычных систем: а) многоязычное смешивание; б) многозадачное обучение

Также многозадачное обучение было применено в работе [60] для ибанского языка, однако в данной работе отдельными задачами являлись распознавание состояний фонем и определение моментов изменения дифференциальных признаков фонем ("landmarks"). Вначале ИНС обучалась на данных английского языка, размеченных на фонемы и "landmarks", а затем выполнялась ее адаптация для малоресурсного ибанского языка на данных, размеченных только на слова, при этом выходные данные детектора "landmarks" для английского языка использовались в качестве справочных меток для обучения акустической модели ибанского языка. Еще одним примером применения многозадачного обучения для малоресурсного языка является [61], где исследуется применение различных типов акустических единиц.

Существуют предварительно обученные многоязычные модели, таких как mBERT или XLM [62-64], в основе которых лежит нейросетевая архитектура трансформер. Эти модели обучены на большом наборе текстов на разных языках и имеют общий для всех языков словарь. Данные модели обучены на примерно 100 языках, и использование их для предварительного обучения малоресурсных языков, не представленных в модели, является недостаточно эффективным. В частности, в работе [65] было показано, что обученная с нуля модель BERT для финского языка превосходит использование mBERT. Однако в работе [66] были проведены

эксперименты по применению предварительно обученных многоязычных моделей для распознавания речи для ряда африканских языков со смешением с английским языком (англ. code-switching), которые показали, что применение таких моделей позволяет снизить WER.

Для сравнения в таблице 2 представлены основные методы переноса знаний, а также относительное снижение ошибки распознавание слов (WER)/символов (CER), полученное различными исследователями за счет применения представленных методов.

Таблица 2. Результаты применения метода переноса знаний для малоресурсных языков

| Работа | Нецелевой язык (языки) | Целевой язык | Методы  | Относительное сокращение ошибки распознавания слов (WER, %) |
|--------|------------------------|--------------|---|---|
| [54]   | нидерландский          | африкаанс    | Гетероскедастический линейный дискриминантный анализ и адаптация к речи диктора     | 34,34 <sup>‡</sup>  |
| [55]   | английский + путунхуа  | амхарский    | Перенос параметров предобученной модели для инициализации параметров целевой модели | 37,73   |
| [56]   | английский             | сенека       | Перенос знаний  | 25,05   |
|        |                        |              | Перенос знаний + аугментация  | 41,13   |

<sup>‡</sup> В данной работе в качестве метрики используется ошибка распознавания букв (CER, %).

Продолжение Таблицы 2

| Работа | Нецелевой язык (языки) | Целевой язык   | Методы  | Относительное сокращение ошибки распознавания слов (WER, %) |
|--------|------------------------|--|---|---|
| [57]   | английский             | швейцарский<br>немецкий                              | Перенос параметров предобученной модели без заморозки параметров  | -2,70   |
|        |                        |  | С заморозкой параметров 1 и 2 слоя ИНС  | 9,46  |
| [58]   | амхарский,             | Языки из GlobalPhone + речевые данные близкого языка | Переносились веса скрытых слоев, а веса выходного слоя дообучались для каждого целевого языка на данных этого языка | 2,61  |
|        | тигринья               |  |   | -0,48   |
|        | оромо                  |  |   | 0,87  |
|        | воламо                 |  |   | 1,81  |
| [59]   | уйгурский              | Языки из GlobalPhone                                 | Перенос параметров многоязычной модели в целевую модель   | 33,21   |
| [60]   | ибан                   | Языка из TIMT  | Многозадачное обучение  | 1,90-5,90 (в зависимости от количества обучающих данных)    |
| [66]   | зулу                   | M-BERT, 104 языка                                    | GPT-2 LSTM  | 5,53  |
|        | коса                   |  |   | 2,09  |
|        | сесото                 |  |   | 50,07   |
|        | тсвана                 |  |   | 41,00   |

Следует отметить, что конечный результат работы системы распознавания определяется не только примененными авторами методами переноса знаний, а также используемыми наборами обучающих данных и архитектурой ИНС. Несмотря на невозможность прямого сравнения результатов, полученных в работах из таблицы 2, можно сделать вывод о том, что применение методов переноса знаний

позволяет снизить ошибки распознавания, однако итоговый результат сильно зависит от качества и количества обучающих данных, а также примененного классификатора.

**7. Заключение.** В настоящей статье были рассмотрены основные методы, применяемые при создании систем распознавания речи для малоресурсных языков. Двумя главными способами решения этой проблемы являются расширение обучающих корпусов (аугментация данных) и перенос параметров моделей, обученных на данных других языков, для инициализации параметров модели целевого языка (перенос знаний). В целом, можно констатировать, что оба подхода позволяют достичь определенных результатов, однако каждый из них обладает определенными достоинствами и недостатками.

Методы аугментации могут быть признаны оправданными только в том случае, если для конкретного малоресурсного языка уже существуют какие-то наборы данных. В том случае, если доступные языковые данные чрезвычайно малы, аугментации может быть недостаточно. С другой стороны, при наличии данных, аугментирование языкового материала зачастую оказывается единственным способом создания набора данных для обучения.

Количественное сравнение различных методов переноса знаний затруднено, поскольку, в конечном итоге, результат зависит не только от примененного метода, но и от набора данных. Тем не менее, можно сделать вывод о том, что в том случае, если доступны данные по языку с достаточными ресурсами, имеет смысл работать не с несколькими языками, а с одной языковой парой. В отличие от многозадачных систем, в данном случае осуществляется прямой перенос знаний с одной модели языка на другую. Метод переноса знаний стал широко использоваться в системах автоматического распознавания речи с развитием глубоких ИНС, чаще всего он применяется при разработке интегральных систем распознавания речи. Данный подход особенно эффективен при наличии предобученной модели для языка, близкого целевому, однако даже для сильно отличающихся друг от друга языков данный метод позволяет повысить точность распознавания речи [67]. Для небольших наборов языковых данных модель, использующая многозадачное обучение, может существенно превзойти модель, разработанную для решения одной задачи.

Хотя многоязычные модели сталкиваются с рядом проблем, таких, как использование большого количества разноструктурных языков, дисбаланс данных и другие расхождения, касающиеся таких факторов, как стиль и предметная область [68, 69], тем не менее,

многоязычный подход на сегодня является наиболее перспективным из всех существующих систем: так, одной из наиболее эффективных многоязычных моделей, применяемых к материалу малоресурсных языков, является многоязычный mBART [70]. Также стоит отметить, что многоязычный подход позволяет решить такую проблему, как смешение языков, особенно характерную для многих малоресурсных языков.

В целом, на основании рассмотренных работ можно сделать вывод о том, что основным вектором развития речевых технологий для работы с малоресурсными языками, помимо собственно сбора и аннотации языковых данных, является создание сбалансированных многоязычных систем, пригодных для создания акустических и языковых моделей в рамках конкретных групп близкородственных или структурно схожих языков.

С 2022 года сотрудниками СПб ФИЦ РАН ведутся работы в рамках проекта по созданию системы автоматического распознавания речи на карельском языке (ливвиковское наречие). Несмотря на давнюю литературную традицию и интерес лингвистов к языку и фольклору карел, карельский язык относится к малоресурсным. На момент написания этой статьи основные усилия участников проекта были направлены на сбор и предварительную обработку речевых и текстовых данных, в дальнейшем планируется применить методы аугментации данных, а также использовать метод переноса знаний при обучении моделей.

### Литература

1. Magueresse A., Carles V., Heetderks E. Low-resource Languages: A Review of Past Work and Future Challenges // arXiv preprint arXiv:2006.07264. 2020. pp. 1–14.
2. Joshi P., Santy S., Budhiraja A., Bali K., Choudhury M. The State and Fate of Linguistic Diversity and Inclusion in the NLP World // Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics. 2020. pp. 6282–6293.
3. Bender E.M. On achieving and evaluating language-independence in NLP. Linguistic Issues in Language Technology. 2011. vol. 6. no. 3. pp. 1–26.
4. Ponti E.M., O’Horan H., Berzak Y., Vulic I., Reichart R., Poibeau T., Shutova E., Korhonen A. Modeling language variation and universals: A survey on typological linguistics for natural language processing // Computational Linguistics. 2019. vol. 45. no. 3. pp. 559–601.
5. Krauwer S. The basic language resource kit (BLARK) as the first milestone for the language resources roadmap // Proceedings of International workshop on speech and computer (SPECOM-2003). 2003. pp. 8–15.
6. Berment V. Méthodes pour informatiser des langues et des groupes de langues «peu dotées». Doct. Diss. Grenoble, 2004.

7. Cieri Ch., Maxwell M., Strassel S., Tracey J. Selection criteria for low resource language programs // *Proceedings of the Tenth International Conference on Language Resources and Evaluation (LREC'16)*. 2016. pp. 4543–4549.
8. Tsvetkov Y. 2017. Opportunities and challenges in working with low-resource languages. Presentation. Carnegie Mellon University, June 22, 2017.
9. Романенко А.Н. Робастное распознавание речи для низко-ресурсных языков. дис. канд. техн. наук: 05.13.11 Ульм. 2020 (на правах рукописи).
10. Мурадова А.Р. Как исчезают языки и как их возрождают // *Языковое разнообразие в киберпространстве: российский и зарубежный опыт. Сборник аналитических материалов М.: МЦБС, 2008. С. 70–75.*
11. Хусаинов А.Ф., Сулейманов Д.Ш. Система автоматического распознавания речи на татарском языке // *Программные продукты и системы*. 2013. №4. С. 31–34.
12. Израилова Э.С. О создании фонетико-акустической базы в рамках синтеза чеченской речи // *Компьютерная лингвистика и обработка естественного языка*. 2017. №2. С. 111–115.
13. Boyko T., Zaitseva N., Krizhanovskaya N., Krizhanovsky A., Novak I., Pellinen N., Rodionova A. The Open corpus of the Veps and Karelian languages: overview and applications // *KnE Social Sciences*. 2022. vol. 7. no. 3. pp. 29–40.
14. Марковников Н.М., Кипяткова И.С. Аналитический обзор интегральных систем распознавания речи // *Труды СПИИРАН*. 2018. Вып. 58. С. 77–110.
15. Besacier L., Barnard E., Karpov A., Schultz T. Automatic speech recognition for under-resourced languages: A survey // *Speech communication*. 2014. vol. 56. pp. 85–100.
16. Карпов А.А., Верходанова В.О. Речевые технологии для малоресурсных языков мира. // *Вопросы языкознания*. 2015. № 2. С. 117–135.
17. Sabou M., Bontcheva K., Derczynski L., Scharl A. Corpus Annotation through Crowdsourcing: Towards Best Practice Guidelines // *Proceedings of the Ninth International Conference on Language Resources and Evaluation (LREC'14)*. 2014. pp. 859–866.
18. Arora S., Arora K.K., Roy M.K., Agrawal S.S., Murthy B.K. Collaborative speech data acquisition for under resourced languages through crowdsourcing // *Procedia Computer Science*. 2016. vol. 81. pp. 37–44.
19. Schultz T., Schlippe T. GlobalPhone: Pronunciation Dictionaries in 20 Languages // *Proceedings of the Ninth International Conference on Language Resources and Evaluation (LREC'14)*. 2014. pp. 337–341.
20. Strassel S., Tracey J. LORELEI Language Packs: Data, Tools, and Resources for Technology Development in Low Resource Languages // *Proceedings of the Tenth International Conference on Language Resources and Evaluation (LREC'16)*, 2016. pp. 3273–3280.
21. Simpson H., Cieri Ch., Maeda K., Baker K., Onyshkevych B. Human language technology resources for less commonly taught languages: Lessons learned toward creation of basic language resources // *Collaboration: interoperability between people in the creation of language resources for less-resourced languages*. 2008. vol. 7. pp. 7–11.
22. Do V.H., Chen N.F., Lim B.P., Hasegawa-Johnson M.A. Acoustic Modeling for Under-resourced Language using Mismatched Transcriptions // *International Journal of Asian Language Processing*. 2017. vol. 27. no. 2. pp. 141–153.
23. Hasegawa-Johnson M.A., Jyothi P., McCloy D., Mirbagheri M., Liberto, di G.M. Das A., Ekin B., Liu Ch., Manohar V., Tang H., Lalor E., Chen N.A. Hager P., Kekona T., Sloan R., Lee A.K.C. ASR for under-resourced languages from probabilistic transcription // *IEEE/ACM Transactions on Audio, Speech, and Language Processing*. 2017. vol. 25. no. 1. pp. 50–63.

24. Yu C., Kang M., Chen Y., Wu J., Zhao X. Acoustic modeling based on deep learning for low-resource speech recognition: An overview // *IEEE Access*. 2020. vol. 8. pp. 163829-163843.
25. Ko T., Peddinti V., Povey D., Khudanpur S. Audio augmentation for speech recognition // *Proceedings of the 16th Annual Conference of the International Speech Communication Association*. 2015. pp. 3586-3589.
26. Rebai I., BenAyed Y., Mahdi W., Lorré J.P. Improving speech recognition using data augmentation and acoustic model fusion // *Procedia Computer Science*. 2017. vol. 112. pp. 316-322.
27. Park D.S., Chan W., Zhang Y., Chiu C.C., Zoph B., Cubuk E.D., Le Q.V. SpecAugment: A Simple Data Augmentation Method for Automatic Speech Recognition // *Proceedings of Interspeech*. 2019. pp. 2613-2617.
28. Hartmann W., Ng T., Hsiao R., Tsakalidis S., Schwartz R. Two-Stage Data Augmentation for Low-Resourced Speech Recognition // *Proceedings of Interspeech*. 2016. pp. 2378-2382.
29. Jin Z., Finkelstein A., DiVerdi S., Lu J., Mysore G.J. Cute: A concatenative method for voice conversion using exemplar-based unit selection // *Proceedings of 2016 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP'16)*. 2016. pp. 5660-5664.
30. Goodfellow I.J., Pouget-Abadie J., Mirza M., Xu B., Warde-Farley D., Ozair Sh., Courville A., Bengio Y. Generative adversarial nets // *Advances in Neural Information Processing Systems 27 / Z. Ghahramani, M. Welling, C. Cortes, N. D. Lawrence, K. Q. Weinberger (eds.)*. pp. 2672-2680 // *Curran Associates, Inc.*, 2014.
31. Hsu Ch.-Ch., Hwang H.-T., Wu Y.-Ch., Tsao Y., Wang H. Voice Conversion from Unaligned Corpora Using Variational Autoencoding Wasserstein Generative Adversarial Networks // *arXiv preprint arXiv:1704.00849*. 2017. pp. 1-5.
32. Kameoka H., Kaneko T., Tanaka K., Hojo N. StarGAN-VC: non-parallel many-to-many Voice Conversion Using Star Generative Adversarial Networks // *Proceedings of 2018 IEEE Spoken Language Technology Workshop (SLT'18)*. 2018. pp. 266-273.
33. Gokay R., Yalcin H. Improving low resource turkish speech recognition with data augmentation and TTS // *Proceedings of 2019 16th International Multi-Conference on Systems, Signals and Devices (SSD)*. 2019. pp. 357-360.
34. Shen J., Pang R., Weiss R.J., Schuster M., Jaitly N., Yang Z., Chen Z., Zhan Y., Wang Y., Skerfvr-Ryan R., Saurous R.A., Agiomvrgiannakis Y., Wu Y. Natural TTS Synthesis by Conditioning WaveNet on Mel Spectrogram Predictions // *Proceedings of 2018 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. 2018. pp. 4779-4783.
35. Dua M., Kadyan V., Banthia N., Bansal A., Agarwal T. Spectral warping and data augmentation for low resource language ASR system under mismatched conditions // *Applied Acoustics*. 2022. vol. 190. 108643.
36. Du C., Yu K. Speaker augmentation for low resource speech recognition // *Proceedings of 2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. 2020. pp. 7719-7723.
37. Bagchi D., Wotherspoon Sh., Jiang Zh., Muthukumar P. Speech Synthesis as Augmentation for Low-Resource ASR // *arXiv preprint arXiv:2012.13004*. 2020. pp. 1-4.
38. Hsu B.J. Generalized linear interpolation of language models // *Proceedings of 2007 IEEE workshop on automatic speech recognition & understanding (ASRU)*. 2007. pp. 136-140.
39. Kurimo M., Enarvi S., Tilk O., Varjokallio M., Mansikkaniemi A., Alumäe T. Modeling under-resourced languages for speech recognition // *Language Resources and Evaluation*. 2017. vol. 51. no. 4. pp. 961-987.

40. Fadaee M., Bisazza A., Monz Ch. 2017. Data Augmentation for Low-Resource Neural Machine Translation // Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics. 2017. pp. 567–573.
41. Şahin G.G. To Augment or Not to Augment? A Comparative Study on Text Augmentation Techniques for Low-Resource NLP // Computational Linguistics. 2022. vol. 48. no. 1. pp. 5–42.
42. Kobayashi S. Contextual Augmentation: Data Augmentation by Words with Paradigmatic Relations // Proceedings of the 2018 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies. Vol. 2 (Short Papers). 2018. pp. 452–457.
43. Kumar V., Choudhary A., Cho E. Data Augmentation using Pre-trained Transformer Models // Proceedings of the 2nd Workshop on Life-long Learning for Spoken Language Systems. 2020. pp. 18–26.
44. Ogawa A., Tawara N., Delcroix M. Language Model Data Augmentation Based on Text Domain Transfer // Proceedings of Interspeech. 2020. pp. 4926–4930.
45. Sennrich R., Haddow B., Birch A. Improving Neural Machine Translation Models with Monolingual Data // Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics. 2016. pp. 86–96.
46. Shah Nawazuddin S., Nagaraj A., Kunal K., Aayushi P., Waqar A. Voice Conversion Based Data Augmentation to Improve Children Speech Recognition in Limited Data Scenario // Proceedings of Interspeech 2020. pp. 4382–4386.
47. Tachibana H., Uenoyama K., Aihara S. Efficiently trainable text-to-speech system based on deep convolutional networks with guided attention // Proceedings of IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). 2018. pp. 4784–4788.
48. Edunov S., Ott M., Auli M., Grangier D. Understanding Back-Translation at Scale // Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing. 2018. pp. 489–500.
49. Fadaee M., Monz Ch. Back-Translation Sampling by Targeting Difficult Words in Neural Machine Translation // Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing. 2018. pp. 436–446.
50. Karakanta A., Dehdari J., Genabith, van J. Neural machine translation for low-resource languages without parallel corpora // Machine Translation. 2018. vol. 32. no. 1-2. pp. 167–189.
51. Xia M., Kong X., Anastasopoulos A., Neubig G. Generalized Data Augmentation for Low-Resource Translation // Proceedings of the 57th Annual Meeting of the ACL. 2019. pp. 5786–5796.
52. Wang D., Zheng T.F. Transfer learning for speech and language processing // Proceedings of 2015 Asia-Pacific Signal and Information Processing Association Annual Summit and Conference (APSIPA). 2015. pp. 1225–1237.
53. Gauvain J.-L., Lee C.-H. Maximum a posteriori estimation for multivariate Gaussian mixture observations of Markov chains // IEEE Transactions on Speech and audio processing. 1994. vol. 2. no. 2. pp. 291–298.
54. Wet, de F., Kleynhans N., Compennolle, van D., Sahraeian, R. Speech recognition for under-resourced languages: Data sharing in hidden Markov model systems // South African Journal of Science. 2017. vol. 113. no. 1–2. pp. 1–9.
55. Woldemariam Y. Transfer Learning for Less-Resourced Semitic Languages Speech Recognition: the Case of Amharic // Proceedings of the 1st Joint Workshop on Spoken Language Technologies for Under-resourced languages (SLTU) and Collaboration and Computing for Under-Resourced Languages (CCURL). 2020. pp. 61–69.



56. Thai B., Jimerson R., Arcoraci D., Prud'hommeau E., Ptucha R. Synthetic data augmentation for improving low-resource ASR // Proceedings of 2019 IEEE Western New York Image and Signal Processing Workshop (WNYISPW). 2019. pp. 1–9.
57. Eberhard O., Zesch T. Effects of Layer Freezing on Transferring a Speech Recognition System to Under-resourced Languages // Proceedings of the 17th Conference on Natural Language Processing (KONVENS 2021). 2021. pp. 208–212.
58. Tachbelie M.Y., Abate S.T., Schultz T. Development of Multilingual ASR Using GlobalPhone for Less-Resourced Languages: The Case of Ethiopian Languages // Proceedings of Interspeech. 2020. pp. 1032–1036.
59. Tachbelie M.Y., Abate S.T., Schultz T. Multilingual speech recognition for GlobalPhone languages // Speech Communication. 2022. vol. 140. pp. 71–86.
60. He D., Lim B.P., Yang X., Hasegawa-Johnson M.A., Chen D. Improved ASR for under-resourced languages through multi-task learning with acoustic landmarks // Proceedings of Interspeech. 2018. pp. 2618–2622.
61. Fantaye T.G., Yu J., Hailu T.T. Investigation of Various Hybrid Acoustic Modeling Units via a Multitask Learning and Deep Neural Network Technique for LVCSR of the Low-Resource Language, Amharic // IEEE Access. 2019. T. 7. pp. 105593–105608.
62. Açarçipek H., Çolakoğlu T., Hatipoğlu P., Huang Ch.H., Peng W. Filtering Noisy Parallel Corpus using Transformers with Proxy Task Learning // Proceedings of the Fifth Conference on Machine Translation. 2020. pp. 940–946.
63. Keung Ph., Salazar J., Lu Y., Smith N.A. Unsupervised Bitext Mining and Translation via Self-Trained Contextual Embeddings // Transactions of the Association for Computational Linguistics. 2020. vol. 8. pp. 828–841.
64. Sun Y., Zhu Sh., Yifan F., Mi Ch. Parallel sentences mining with transfer learning in an unsupervised setting // Proceedings of the 2021 Conference of the North American Chapter of the Association for Computational Linguistics: Student Research Workshop. 2021. pp. 136–142.
65. Virtanen A., Kanerva J., Ilo R., Luoma J., Luotolahti J., Salakoski T., Ginter F., Pyysalo S. Multilingual is not enough: BERT for Finnish // arXiv preprint arXiv:1912.07076. 2019. pp. 1–14.
66. Vüren, van J.M.J., Niesler T. Improving N-Best Rescoring in Under-Resourced Code-Switched Speech Recognition Using Pretraining and Data Augmentation // Preprints. 2022. 2022050066.
67. Кипяткова И.С., Марковников Н.М. Исследование методов улучшения интегральных систем распознавания речи при недостатке обучающих данных // Труды III Всероссийской акустической конференции. 2020. С. 361–367.
68. Arivazhagan N., Bapna A., Firat O., Lepikhin D., Johnson M., Krikun M., Chen M.X., Cao Y., Foster G., Cherry C., Macherey W., Chen Zh., Wu Y. Massively multilingual neural machine translation in the wild: Findings and challenges // arXiv preprint arXiv:1907.05019. 2019. pp. 1–27.
69. Chathuranga Sh., Ranathunga S. Classification of Code-Mixed Text Using Capsule Networks // Proceedings of the International Conference on Recent Advances in Natural Language Processing (RANLP 2021). 2021. pp. 256–263.
70. Stickland A.C., Li X., Ghazvininejad M. Recipes for Adapting Pre-trained Monolingual and Multilingual Models to Machine Translation // Proceedings of the 16th Conference of the European Chapter of the Association for Computational Linguistics: Main Volume. 2021. pp. 3440–3453.

**Кипяткова Ирина Сергеевна** — канд. техн. наук, старший научный сотрудник, лаборатория речевых и многомодальных интерфейсов, Санкт-Петербургский Федеральный исследовательский центр Российской академии наук (СПб ФИЦ РАН).

Область научных интересов: автоматическое распознавание речи, нейронные сети. Число научных публикаций — 100. kiryatkova@iias.spb.su; 14-я линия В.О., 39, 199178, Санкт-Петербург, Россия; р.т.: 8(812)328-0421.

**Кагиров Ильдар Амирович** — научный сотрудник, лаборатория речевых и многомодальных интерфейсов, Санкт-Петербургский Федеральный исследовательский центр Российской академии наук (СПб ФИЦ РАН). Область научных интересов: корпусная лингвистика, малоресурсные языки. Число научных публикаций — 40. kagirov@iias.spb.su; 14-я линия В.О., 39, 199178, Санкт-Петербург, Россия; р.т.: 8(812)328-0421.

**Поддержка исследований.** Работа выполнена при финансовой поддержке фонда РФФ (проект № 22-21-00843).

I. KIPYATKOVA, I. KAGIROV  
**ANALYTICAL REVIEW OF METHODS FOR SOLVING DATA  
SCARCITY ISSUES REGARDING ELABORATION OF  
AUTOMATIC SPEECH RECOGNITION SYSTEMS FOR LOW-  
RESOURCE LANGUAGES**

*Kipyatkova I., Kagirov I. Analytical Review of Methods for Solving Data Scarcity Issues Regarding Elaboration of Automatic Speech Recognition Systems for Low-Resource Languages.*

**Abstract.** In this paper, principal methods for solving training data issues for the so-called low-resource languages are discussed, regarding elaboration of automatic speech recognition systems. The notion of low-resource languages is studied and a working definition is coined on the basis of a number of papers on this topic. The main difficulties associated with the application of classical approaches to automatic speech recognition to the material of low-resource languages are determined, and the principal methods used to solve these problems are outlined. The paper discusses the methods for data augmentation, transfer learning and collection of new language data in detail. Depending on specific tasks, methods for audio material and text data augmentation, transfer learning and multi-task learning are distinguished. In Section 4 of the paper the current information support methods, databases and the basic principles of their architecture are discussed with regard to low-resource languages. Conclusions are drawn about the justification of augmentation and knowledge transfer methods for languages with low information support. In the case of unavailability of language data or structurally similar parent models, the preferred option is to collect a new database, including the crowdsourcing technique. Multilanguage learning models are effective for small datasets. If big language data are available, the most efficient method is transfer learning within a language pair. The conclusions made in the course of this review will be applied to the data of the low-resource Karelian language, for which an automatic speech recognition system has been being created by the authors of this paper since the beginning of the year 2022.

**Keywords:** low-resource languages, speech data augmentation, transfer learning, machine learning, language corpora.

## References

1. Magueresse A., Carles V., Heetderks E. Low-resource Languages: A Review of Past Work and Future Challenges. arXiv preprint arXiv:2006.07264. 2020. pp. 1–14.
2. Joshi P., Santy S., Budhiraja A., Bali K., Choudhury M. The State and Fate of Linguistic Diversity and Inclusion in the NLP World. Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics. 2020. pp. 6282–6293.
3. Bender E.M. On achieving and evaluating language-independence in NLP. Linguistic Issues in Language Technology. 2011. vol. 6. no. 3. pp. 1–26.
4. Ponti E.M., O’Horan H., Berzak Y., Vulic I., Reichart R., Poibeau T., Shutova E., Korhonen A. Modeling language variation and universals: A survey on typological linguistics for natural language processing. Computational Linguistics. 2019. vol. 45. no. 3. pp. 559–601.
5. Krauwer S. The basic language resource kit (BLARK) as the first milestone for the language resources roadmap. Proceedings of International workshop on speech and computer (SPECOM-2003). 2003. pp. 8–15.
6. Berment V. Méthodes pour informatiser des langues et des groupes de langues «peu dotées». Doct. Diss. Grenoble, 2004.

7. Cieri Ch., Maxwell M., Strassel S., Tracey J. Selection criteria for low resource language programs. Proceedings of the Tenth International Conference on Language Resources and Evaluation (LREC'16). 2016. pp. 4543–4549.
8. Tsvetkov Y. 2017. Opportunities and challenges in working with low-resource languages. Presentation. Carnegie Mellon University, June 22, 2017.
9. Romanenko A.N. [Robust Speech Recognition for Low-Resource Languages.] Robastnoe raspoznavanie rechi dlja nizko-resursnyh jazykov. Diss. Dokt. Estestvennykh Nauk: 05.13.11. [A doctoral thesis for the academic degree of Dr.rer.nat: 05.13.11] Ulm. 2020 (In Russ.).
10. Muradova A.R. [How languages disappear and how they are revived.] Jazykovoe raznoobrazie v kiberprostranstve: rossijskij i zarubezhnyj opyt. [Linguistic Diversity in Cyberspace: Russian and Foreign Experience]. Moscow: MCBS, 2008. pp. 70–75. (In Russ.)
11. Husainov A.F., Suleimanov D.Sh. [A System for Automatic Tatar Speech Recognition]. Programmye produkty i sistemy – Program Products and Systems. 2013. №4. pp. 31–34. (In Russ.)
12. Izrailova E.S. [On Elaboration of a Phono-Acoustic Basis within the Framework of the Chechen Speech]. Komp'juternaja lingvistika i obrabotka estestvennogo jazyka – Computer Linguistics and Natural Language Processing. 2017. №2. pp. 111–115. (In Russ.)
13. Boyko T., Zaitseva N., Krizhanovskaya N., Krizhanovsky A., Novak I., Pellinen N., Rodionova A. The Open corpus of the Veps and Karelian languages: overview and applications. KnE Social Sciences. 2022. vol. 7. no. 3. pp. 29–40.
14. Markovnikov N.M., Kipyatkova I.S. [An Analytic Survey of End-to-End Speech Recognition Systems]. Trudy SPIIRAN – SPIIRAS Proceedings. 2018. vol. 58. pp. 77–110.
15. Besacier L., Barnard E., Karpov A., Schultz T. Automatic speech recognition for under-resourced languages: A survey. Speech communication. 2014. vol. 56. pp. 85–100.
16. Karpov A.A., Verkhodanova V.O. [Speech Technologies for Under-Resourced Languages of the World]. Voprosy Jazykoznanija – Problems of Linguistics. 2015. vol. 2. pp. 117–135. (In Russ)
17. Sabou M., Bontcheva K., Derczynski L., Scharl A. Corpus Annotation through Crowdsourcing: Towards Best Practice Guidelines. Proceedings of the Ninth International Conference on Language Resources and Evaluation (LREC'14). 2014. pp. 859–866.
18. Arora S., Arora K.K., Roy M.K., Agrawal S.S., Murthy B.K. Collaborative speech data acquisition for under resourced languages through crowdsourcing. Procedia Computer Science. 2016. vol. 81. pp. 37–44.
19. Schultz T., Schlippe T. GlobalPhone: Pronunciation Dictionaries in 20 Languages. Proceedings of the Ninth International Conference on Language Resources and Evaluation (LREC'14). 2014. pp. 337–341.
20. Strassel S., Tracey J. LORELEI Language Packs: Data, Tools, and Resources for Technology Development in Low Resource Languages. Proceedings of the Tenth International Conference on Language Resources and Evaluation (LREC'16), 2016. pp. 3273–3280.
21. Simpson H., Cieri Ch., Maeda K., Baker K., Onyshkevych B. Human language technology resources for less commonly taught languages: Lessons learned toward creation of basic language resources. Collaboration: interoperability between people in the creation of language resources for less-resourced languages. 2008. vol. 7. pp. 7–11.

22. Do V.H., Chen N.F., Lim B.P., Hasegawa-Johnson M.A. Acoustic Modeling for Under-resourced Language using Mismatched Transcriptions. *International Journal of Asian Language Processing*. 2017. vol. 27. no. 2. pp. 141–153.
23. Hasegawa-Johnson M.A., Jyothi P., McCloy D., Mirbagheri M., Liberto, di G.M. Das A., Ekin B., Liu Ch., Manohar V., Tang H., Lalor E., Chen N.A. Hager P., Kekona T., Sloan R., Lee A.K.C. ASR for under-resourced languages from probabilistic transcription. *IEEE/ACM Transactions on Audio, Speech, and Language Processing*. 2017. vol. 25. no. 1. pp. 50–63.
24. Yu C., Kang M., Chen Y., Wu J., Zhao X. Acoustic modeling based on deep learning for low-resource speech recognition: An overview. *IEEE Access*. 2020. vol. 8. pp. 163829-163843.
25. Ko T., Peddinti V., Povey D., Khudanpur S. Audio augmentation for speech recognition. *Proceedings of the 16th Annual Conference of the International Speech Communication Association*. 2015. pp. 3586-3589.
26. Rebai I., BenAyed Y., Mahdi W., Lorré J.P. Improving speech recognition using data augmentation and acoustic model fusion. *Procedia Computer Science*. 2017. vol. 112. pp. 316–322.
27. Park D.S., Chan W., Zhang Y., Chiu C.C., Zoph B., Cubuk E.D., Le Q.V. SpecAugment: A Simple Data Augmentation Method for Automatic Speech Recognition. *Proceedings of Interspeech*. 2019. pp. 2613–2617.
28. Hartmann W., Ng T., Hsiao R., Tsakalidis S., Schwartz R. Two-Stage Data Augmentation for Low-Resourced Speech Recognition. *Proceedings of Interspeech*. 2016. pp. 2378-2382.
29. Jin Z., Finkelstein A., DiVerdi S., Lu J., Mysore G.J. Cute: A concatenative method for voice conversion using exemplar-based unit selection. *Proceedings of 2016 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP'16)*. 2016. pp. 5660-5664.
30. Goodfellow I.J., Pouget-Abadie J., Mirza M., Xu B., Warde-Farley D., Ozair Sh., Courville A., Bengio Y. Generative adversarial nets. *Advances in Neural Information Processing Systems 27*. Z. Ghahramani, M. Welling, C. Cortes, N. D. Lawrence, K. Q. Weinberger (eds.). pp. 2672–2680. Curran Associates, Inc., 2014.
31. Hsu Ch.-Ch., Hwang H.-T., Wu Y.-Ch., Tsao Y., Wang H. Voice Conversion from Unaligned Corpora Using Variational Autoencoding Wasserstein Generative Adversarial Networks. *arXiv preprint arXiv:1704.00849*. 2017. pp. 1–5.
32. Kameoka H., Kaneko T., Tanaka K., Hojo N. StarGAN-VC: non-parallel many-to-many Voice Conversion Using Star Generative Adversarial Networks. *Proceedings of 2018 IEEE Spoken Language Technology Workshop (SLT'18)*. 2018. pp. 266–273.
33. Gokay R., Yalcin H. Improving low resource turkish speech recognition with data augmentation and TTS. *Proceedings of 2019 16th International Multi-Conference on Systems, Signals and Devices (SSD)*. 2019. pp. 357–360.
34. Shen J., Pang R., Weiss R.J., Schuster M., Jaitly N., Yang Z., Chen Z., Zhan Y., Wang Y., Skerfvr-Ryan R., Saurous R.A., Agiomvrgiannakis Y., Wu Y. Natural TTS Synthesis by Conditioning WaveNet on Mel Spectrogram Predictions. *Proceedings of 2018 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. 2018. pp. 4779–4783.
35. Dua M., Kadyan V., Banthia N., Bansal A., Agarwal T. Spectral warping and data augmentation for low resource language ASR system under mismatched conditions. *Applied Acoustics*. 2022. vol. 190. 108643.
36. Du C., Yu K. Speaker augmentation for low resource speech recognition. *Proceedings of 2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. 2020. pp. 7719-7723.

37. Bagchi D., Wotherspoon Sh., Jiang Zh., Muthukumar P. Speech Synthesis as Augmentation for Low-Resource ASR. arXiv preprint arXiv:2012.13004. 2020. pp. 1–4.
38. Hsu B.J. Generalized linear interpolation of language models. Proceedings of 2007 IEEE workshop on automatic speech recognition & understanding (ASRU). 2007. pp. 136–140.
39. Kurimo M., Enarvi S., Tilk O., Varjokallio M., Mansikkaniemi A., Alumäe T. Modeling under-resourced languages for speech recognition. Language Resources and Evaluation. 2017. vol. 51. no. 4. pp. 961–987.
40. Fadaee M., Bisazza A., Monz Ch. 2017. Data Augmentation for Low-Resource Neural Machine Translation. Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics. 2017. pp. 567–573.
41. Şahin G.G. To Augment or Not to Augment? A Comparative Study on Text Augmentation Techniques for Low-Resource NLP. Computational Linguistics. 2022. vol. 48. no. 1. pp. 5–42.
42. Kobayashi S. Contextual Augmentation: Data Augmentation by Words with Paradigmatic Relations // Proceedings of the 2018 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies. Vol. 2 (Short Papers). 2018. pp. 452–457.
43. Kumar V., Choudhary A., Cho E. Data Augmentation using Pre-trained Transformer Models // Proceedings of the 2nd Workshop on Life-long Learning for Spoken Language Systems. 2020. pp. 18–26.
44. Ogawa A., Tawara N., Delcroix M. Language Model Data Augmentation Based on Text Domain Transfer. Proceedings of Interspeech. 2020. pp. 4926–4930.
45. Sennrich R., Haddow B., Birch A. Improving Neural Machine Translation Models with Monolingual Data. Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics. 2016. pp. 86–96.
46. Shahnawazuddin S., Nagaraj A., Kunal K., Aayushi P., Waqar A. Voice Conversion Based Data Augmentation to Improve Children Speech Recognition in Limited Data Scenario // Proceedings of Interspeech 2020. pp. 4382–4386.
47. Tachibana H., Uenoyama K., Aihara Sh. Efficiently Trainable Text-to-Speech System Based on Deep Convolutional Networks with Guided Attention. arXiv preprint arXiv:1710.08969. 2017. pp. 1–5.
48. Edunov S., Ott M., Auli M., Grangier D. Understanding Back-Translation at Scale. Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing. 2018. pp. 489–500.
49. Fadaee M., Monz Ch. Back-Translation Sampling by Targeting Difficult Words in Neural Machine Translation. Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing. 2018. pp. 436–446.
50. Karakanta A., Dehdari J., Genabith, van J. Neural machine translation for low-resource languages without parallel corpora. Machine Translation. 2018. vol. 32. no. 1-2. pp. 167–189.
51. Xia M., Kong X., Anastasopoulos A., Neubig G. Generalized Data Augmentation for Low-Resource Translation. Proceedings of the 57th Annual Meeting of the ACL. 2019. pp. 5786–5796.
52. Wang D., Zheng T.F. Transfer learning for speech and language processing. Proceedings of 2015 Asia-Pacific Signal and Information Processing Association Annual Summit and Conference (APSIPA). 2015. pp. 1225–1237.
53. Gauvain J.-L., Lee C.-H. Maximum a posteriori estimation for multivariate Gaussian mixture observations of Markov chains. IEEE Transactions on Speech and audio processing. 1994. vol. 2. no. 2. pp. 291–298.

54. Wet, de F., Kleynhans N., Compernelle, van D., Sahraeiv, R. Speech recognition for under-resourced languages: Data sharing in hidden Markov model systems. *South African Journal of Science*. 2017. vol. 113. no. 1–2. pp. 1–9.
55. Woldemariam Y. Transfer Learning for Less-Resourced Semitic Languages Speech Recognition: the Case of Amharic. *Proceedings of the 1st Joint Workshop on Spoken Language Technologies for Under-resourced languages (SLTU) and Collaboration and Computing for Under-Resourced Languages (CCURL)*. 2020. pp. 61–69.
56. Thai B., Jimerson R., Arcoraci D., Prud'hommeaux E., Ptucha R. Synthetic data augmentation for improving low-resource ASR. *Proceedings of IEEE Western New York Image and Signal Processing Workshop (WNYISPW)*. 2019. pp. 1–9.
57. Eberhard O., Zesch T. Effects of Layer Freezing on Transferring a Speech Recognition System to Under-resourced Languages. *Proceedings of the 17th Conference on Natural Language Processing (KONVENS 2021)*. 2021. pp. 208–212.
58. Tachbelie M.Y., Abate S.T., Schultz T. Development of Multilingual ASR Using GlobalPhone for Less-Resourced Languages: The Case of Ethiopian Languages. *Interspeech*. 2020. pp. 1032–1036.
59. Tachbelie M.Y., Abate S.T., Schultz T. Multilingual speech recognition for GlobalPhone languages. *Speech Communication*. 2022. vol. 140. pp. 71–86.
60. He D., Lim B. P., Yang X., Hasegawa-Johnson M., Chen D. Improved ASR for under-resourced languages through multi-task learning with acoustic landmarks // *Proceedings of Interspeech*. 2018. pp. 2618–2622.
61. Fantaye T.G., Yu J., Hailu T.T. Investigation of Various Hybrid Acoustic Modeling Units via a Multitask Learning and Deep Neural Network Technique for LVCSR of the Low-Resource Language, Amharic. *IEEE Access*. 2019. T. 7. pp. 105593–105608.
62. Açarçipek H., Çolakoğlu T., Hatipoğlu P., Huang Ch.H., Peng W. Filtering Noisy Parallel Corpus using Transformers with Proxy Task Learning. *Proceedings of the Fifth Conference on Machine Translation*. 2020. pp. 940–946.
63. Keung Ph., Salazar J., Lu Y., Smith N.A. Unsupervised Bitext Mining and Translation via Self-Trained Contextual Embeddings. *Transactions of the Association for Computational Linguistics*. 2020. vol. 8. pp. 828–841.
64. Sun Y., Zhu Sh., Yifan F., Mi Ch. Parallel sentences mining with transfer learning in an unsupervised setting. *Proceedings of the 2021 Conference of the North American Chapter of the Association for Computational Linguistics: Student Research Workshop*. 2021. pp. 136–142.
65. Virtanen A., Kanerva J., Ilo R., Luoma J., Luotolahti J., Salakoski T., Ginter F., Pyysalo S. Multilingual is not enough: BERT for Finnish. *arXiv preprint arXiv:1912.07076*. 2019. pp. 1–14.
66. Vüren, van J.M.J., Niesler T. Improving N-Best Rescoring in Under-Resourced Code-Switched Speech Recognition Using Pretraining and Data Augmentation. *Preprints*. 2022. 2022050066.
67. Kipyatkova I.S., Markovnikov N.M. [Investigation of Methods for Improving End-to-End Speech Recognition Systems with a Lack of Training Data.] *Trudy III Vserossijskoj akusticheskoj konferencii. [Proceedings of the 3rd All-Russian Acoustic Conference]*. 2020. pp. 361–367. (In Russ.)
68. Arivazhagan N., Babna A., Firat O., Lepikhin D., Johnson M., Krikun M., Chen M.X., Cao Y., Foster G., Cherry C., Macherey W., Chen Zh., Wu Y. Massively multilingual neural machine translation in the wild: Findings and challenges. *arXiv preprint arXiv:1907.05019*. 2019. pp. 1–27.
69. Chathuranga Sh., Ranathunga S. Classification of Code-Mixed Text Using Capsule Networks. *Proceedings of the International Conference on Recent Advances in Natural Language Processing (RANLP 2021)*. 2021. pp. 256–263.

70. Stickland A.C., Li X., Ghazvininejad M. Recipes for Adapting Pre-trained Monolingual and Multilingual Models to Machine Translation. Proceedings of the 16th Conference of the European Chapter of the Association for Computational Linguistics: Main Volume. 2021. pp. 3440–3453.

**Kipyatkova Irina** — Ph.D., Senior researcher, Speech and multimodal interfaces laboratory, St Petersburg Federal Research Center of the Russian Academy of Sciences (SPC RAS). Research interests: automatic speech recognition, neural networks. The number of publications — 100. kipyatkova@iias.spb.su; 39, 14-th Line V.O., 199178, St. Petersburg, Russia; office phone: 8(812)328-0421.

**Kagirov Ildar** — Researcher, Speech and multimodal interfaces laboratory, St Petersburg Federal Research Center of the Russian Academy of Sciences (SPC RAS). Research interests: corpus linguistics, low-resource languages. The number of publications — 40. kagirov@iias.spb.su; 39, 14-th Line V.O., 199178, St. Petersburg, Russia; office phone: 8(812)328-0421.

**Acknowledgements.** This research is supported by the Russian Science Foundation (project № 22-21-00843).



A. MAHAMUDUL HASHAN, R. MD RAKIB UL ISLAM, K. AVINASH  
**APPLE LEAF DISEASE CLASSIFICATION USING IMAGE  
DATASET: A MULTILAYER CONVOLUTIONAL NEURAL  
NETWORK APPROACH**

*Mahamudul Hashan A., Md Rakib Ul Islam R., Avinash K. Apple Leaf Disease Classification Using Image Dataset: a Multilayer Convolutional Neural Network Approach.*

**Abstract.** Agriculture is one of the prime sources of economic growth in Russia; the global apple production in 2019 was 87 million tons. Apple leaf diseases are the main reason for annual decreases in apple production, which creates huge economic losses. Automated methods for detecting apple leaf diseases are beneficial in reducing the laborious work of monitoring apple gardens and early detection of disease symptoms. This article proposes a multilayer convolutional neural network (MCNN), which is able to classify apple leaves into one of the following categories: apple scab, black rot, and apple cedar rust diseases using a newly created dataset. In this method, we used affine transformation and perspective transformation techniques to increase the size of the dataset. After that, OpenCV crop and histogram equalization method-based preprocessing operations were used to improve the proposed image dataset. The experimental results show that the system achieves 98.40% training accuracy and 98.47% validation accuracy on the proposed image dataset with a smaller number of training parameters. The results envisage a higher classification accuracy of the proposed MCNN model when compared with the other well-known state-of-the-art approaches. This proposed model can be used to detect and classify other types of apple diseases from different image datasets.

**Keywords:** artificial intelligence, apple leaf disease, image processing, multilayer convolutional neural network, classification.

**1. Introduction.** The cultivation area and production of apples in Russia are leading in the world, and it is one of Russia's most important economic crops [1]. Due to the economic growth, apple planting area and production increase every year. Global food security is threatened by climate change (a comprehensive analysis of the individual and combined effects of ozone trends on global climate change 2000-2050) [2] and plant diseases (at least 10% of the world's food production is lost due to plant diseases) [3]. In developing countries like Bangladesh, the identification of plant diseases is done by visual observation by the farmers, where proper identification of the diseases usually depends on the skill, experience, and ability of the farmers. There is always a risk of incorrect detection and classification of plant diseases. Sometimes, the agronomists may fail to properly identify leaf disease. This is a big challenge to accurately identify leaf disease, timely treat, and protect crop from damage.

In recent years, computer vision and deep learning techniques have been widely used in agriculture, and a number of methods for the identification of crop diseases have been acquired [4, 5]. Popular methods that are widely used to detect crop diseases include artificial neural network

(ANN) [6], K Nearest Neighbors (KNN) algorithm [7], and so on. There are several diseases that attack apples, the major ones are apple scab (*Venturia inaequalis*), Apple black rot (*Botryosphaeria obtusa*), and apple cedar rust (*Gymnosporangium juniperi-virginianae*). The proper care of apple trees using fertilizers can help the farmers. However, apple leaf diseases cause low production, financial losses, and a decrease in the quality of fruit industry products. Therefore, there is a necessity of accurate methods for detecting apple leaf diseases and preventing losses by taking proper actions.

To solve this problem, early detection of apple leaf diseases is necessary. Manual detection of apple leaf diseases is carried out either by farmers or agricultural scientists. Manual detection is a challenging and time-consuming task. To address this problem, many researchers around the world have introduced various state-of-the-art systems for automatic detection of apple leaf diseases through different machine learning [8, 9] and deep learning [10, 11] methods. However, these existing systems use a very high number of training parameters and a large number of datasets. Therefore, the training and prediction time of these systems is very long and requires high computing power. There are two noticeable advantages of deep learning methods over machine learning methods. First, they automatically extract various features from raw data, so there is no need for an additional feature extraction module. Second, deep learning methods reduce the time required to process large, high-dimensional datasets.

This paper proposes an MCNN model for automatic apple leaf disease classification with fewer training parameters. In addition, the research includes effective data augmentation and image preprocessing operations. The proposed method boosts the apple leaf disease recognition accuracy and reduces computational time. The rest of the paper is arranged into four sections. Section 2 discusses several state-of-the-art methods for the automatic detection and classification of apple leaf diseases described in the literature. In Section 3, the methods used to design the multilayer convolution neural network are described. The results from the apple leaf disease classification model are presented in Section 4 and Section 5 conclusions.

**2. Related Works.** Modern technology makes the agriculture sector more advanced by early disease detection and reduction of human efforts. There are various techniques for automated detection and classification systems using deep learning, such as brain tumor detection using MRI images [12], tomato crop disease classification using deep learning [13], and so on.

In order to improve the accuracy of deep neural networks, Xie et al. [14] proposed a real-time grape leaf disease detector using improved deep

convolutional neural networks. Initially enlarges the grape leaf disease image using digital imaging technology and creates a grape leaf disease (GLDD) dataset. Based on GLDD and the Faster R-CNN detection algorithm, a deep learning-based Faster DR-IACNN model with a higher feature extraction capability for grape leaf disease detection is presented. The implemented detection model Faster DR-IACNN achieves a precision of 81.1% mAP on GLDD, and the detection speed reaches 15.01 FPS. Sun et al. [15] proposed three major steps to detect maize leaf blight diseases using a convolutional neural network. They recommended a way to consolidate dataset preprocessing, fine-tuning network, and detection module. They claimed in their paper, that data preprocessing reduced the influence of high-intensity light on image identification and improved accuracy. They used the loss function with Generalized Intersection Over Union (GIoU) to optimize the detection processes. The proposed model achieved the highest mean average precision (mAP) 91.83%. Sabrol et al. [16] proposed a system to identify tomato plant disease by using a tree classifier model from the tomato leaf image dataset. The classification was conducted by extracting color, shape and texture features from tomato plant images. Five types of tomato diseases and one healthy were classified which used 382 tomato images and overall 97.3% of classification accuracy was achieved.

Aiming at the complexity of identifying apple leaves disease, Yadav et al. [17] presented an automatic technique for apple leaves disease detection using a convolutional neural network. This model uses preprocessing and fuzzy c-mean clustering for the identification and classification of apple leaves disease. Authors claim that the proposed model provided overall 98% accuracy. Also, Baranwal et al. [18] presented an automatic technique for apple leaves disease detection using a convolutional neural network at SUSCOM-19 which was organized by Amity University in India. The dataset with 1000 samples of healthy leaf image and 1526 unhealthy leaf images are used in their project. Image Compression and filtering techniques with convolutional neural networks are used for the automatic identification of apple leaves disease. The convolutional neural network model is used similarly to the LetNet architecture and the proposed model has offered 98.54% apple leaves disease detection accuracy.

Traditional deep learning methods have large progress in the leaf disease recognition field. Bin Liu et al. [19] introduced a novel architecture of a deep convolutional neural network based on AlexNet for the identification of apple leaves diseases using a dataset that included 13689 images. The Google Net's inception is utilized to enhance and boost the

feature extraction ability. The image processing techniques are applied to avoid overfitting in the training processes. Nesterov's Accelerated Gradient (NAG) optimization algorithm is applied to train the CNN-based model. This proposed novel CNN model architecture automatically detects leaf diseases with 97.62% accuracy. Kerkech et al. [20] proposed a model for automatic vine disease detection using the registration method on Unmanned Aerial Vehicle (UAV) image dataset. Also, they used a traditional CNN model to classify each pixel according to different instances. They claimed that the proposed method achieved more than 92% of apprehension at the level of grapevine and 87% at the leaf level.

Sanga et al. [21] proposed a disease detection application for banana plants using five different convolutional neural network architectures (VGG-16, ResNet-152, ResNet-50, ResNet-18, and InceptionV3). They found that ResNet-152 architecture performed an accuracy of 99.2%, which is better than other models. They also proposed a mobile application, so that farmers could easily detect diseases by uploading banana leaf images with their smartphones. Chohan et al [22] proposed a similar work using VGG-19 and InceptionV3 CNN architectures for automatic plant disease detection and classification using the PlantVillage image dataset. They used data augmentation to enlarge the dataset. They claimed in their paper, that the VGG-19 model performed with 98% training accuracy, and the InceptionV3 model performed with 95% testing accuracy.

Dealing with YOLO architecture, Wu et al. [23] introduced the YOLOv4 model and data augmentation methods for the apple picking robot to identify apples quickly and accurately. They used EfficientNet architecture and convolution layer (Conv2D), instead of Cross Stage Partial Darknet53 (CSPDarknet53) due to the extensive size and calculation of the YOLOv4 Model. The apple identification is performed on 2670 samples and the test result shows that the EfficientNet-B0-YOLOv4 model is better than YOLOv3, YOLOv4, and Faster R-CNN. The proposed EfficientNet-B0-YOLOv4 model offers accurate identification results, and it can be used for the vision system of picking robots in the apple industry. Coulibaly et al. [24] introduced a disease detection system for millet crops in the agricultural sector. Their approach was used to extract millet crops leaf's features based on the transfer learning technique of the neural network model. The test dataset used to evaluate the performance of the model includes 18 images with diseases and 9 images without diseases. A pre-trained VGG16 model had been used to transfer its learning ability to their proposed CNN network, where the best accuracy achieved 95%, precision of 90.50%, recall of 94.50% and the f1-score of 91.75%.

In this study, we proposed a multilayer convolutional neural network

(MCNN), data augmentation methods, and image preprocessing methods to overcome the drawbacks of the previous methods and provide a practical solution. The limitations of the previous study and the main contributions of this study are summarized as follows:

1. The previous models have limitations in properly taking advantage of data augmentation techniques. The proposed model uses various image augmentation techniques such as affine transformation and perspective transformation to enhance the proposed dataset.

2. All of the studies reviewed above used a large number of learning parameters. Training a model with a large number of training parameters requires high computing power. Proposed multilayer convolutional neural network that reduces the dimensionality of the input of apple leaf images using image preprocessing operations such as the OpenCV crop method and the histogram equalization method. Reducing the dimension of apple leaf images before classification reduces the number of training parameters.

**3. Material and Methods.** This section discusses the materials and methods that elaborate the proposed model. Figure 1 shows the flow diagram of the overall systems, which lists the main steps. The detailed work of these processes is presented in the following subsections.




Fig. 1. Workflow for the whole system

**3.1. Proposed Dataset.** Dataset is one of the most important parts of a training network; we analyzed 480 images of apple leaves with high resolution. All the images collected for the dataset were downloaded from the Internet and searched for apple leaf diseases from various sources in different languages such as English, Russian, Bengali, and Hindi. The images in the dataset were grouped into three different classes. The dataset images consist of apple black rot, apple cedar rust, and apple scab which are three common apple leaf diseases (Figure 2).

In order to avoid duplicate images, the comparing procedure was applied to remove duplicate apple leaf images using a developed python script. The script removed all duplicate apple leaf images by comparing metadata such as image name, size, and date. After that, the images were evaluated by human experts. The next step was to increase the apple leaf images dataset with augmented images. The main idea of this study is to train MCNN to learn the features of apple leaf images. Therefore, the chance to learn appropriate features was increased by using more augmented apple leaf images for the MCNN network. The image data augmentation process is described in Section 3.2. Finally, an apple leaf image dataset containing 3840 augmented images and 1141 images for validation has been created (Table 1). All apple leaf images are in RGB color and JPG format.



Fig. 2. Apple leaf disease images from the proposed dataset: (a) apple black rot leaves; (b) apple cedar rust leaves; (c) apple scab leaves

**3.2. Data Augmentation.** The main purpose of using data augmentation is to enlarge the dataset and introduce slight distortions in images, which helps to reduce overfitting during the training phase. OpenVX supports two commonly used image enlargement methods, which are affine transformation and perspective transformation [25]. In the affine transformation, we need three points from the input images and their corresponding locations in the output images. Affine transformation creates an  $a^{2 \times 3}$  matrix, which defines a pixel coordinate mapping from the output to the input image following Equation (1):

$$\begin{aligned}x_0 &= M_{1,1}x + M_{2,1}y + M_{3,1}, \\y_0 &= M_{1,2}x + M_{2,2}y + M_{2,3}.\end{aligned}\quad (1)$$

Where,  $x_0, y_0$  and  $x, y$  = coordinates of a pixel in the input and output images, and  $M$  = affine matrix. Perspective transformation creates a  $3 \times 3$  transformation matrix. It requires 4 points in the input image and corresponding points in the output image. The perspective transformation is defined by an  $a^{3 \times 3}$  matrix following Equation (2).

$$\begin{aligned}x_u &= M_{1,1}x + M_{2,1}y + M_{3,1}, \\y_u &= M_{1,2}x + M_{2,2}y + M_{2,3}, \\z_u &= M_{1,3}x + M_{2,3}y + M_{3,3}.\end{aligned}\quad (2)$$

Where,  $x, y$  = pixel coordinates of the output image, and  $x_u, y_u, z_u$  = uniform pixel coordinates of the input image. These two transformations are applied in the proposed dataset (Figure 3), where the first image is an affine transformation; the second image represents a perspective transformation.




Fig. 3. Image transformations used for augmentation: (a) affine transformation; (b) perspective transformation

Table 1 shows the diseases along with the number of original images and the number of augmented images for each class. Additionally, it shows validation images for the disease classification model. Separating the data into training and test sets helps us find the best model and prevent overfitting. We run the experiments across a whole range of train-validation sets (where, 80% of the whole dataset is used for training, and the rest 20% for validation).

Table 1. Dataset for image classification of apple leaf disease

| Disease Class    | Original Images | Augmented Images | Validation Images |
|------------------|-----------------|------------------|-------------------|
| Apple Black Rot  | 170             | 1360             | 228               |
| Apple Cedar Rust | 160             | 1280             | 114               |
| Apple Scab       | 150             | 1200             | 285               |
| Total            | 480             | 3840             | 1141              |

**3.3. Image Preprocessing.** Preprocessing is a familiar name for operation on images, and it helps to improve the image data for further processes. The two different methods are used in the preprocessing stage, namely the OpenCV crop method for resizing the images and the histogram equalization method for contrast enhancement. The images captured may have different shapes and proportions, so the pictures are preprocessed and taken to the same size, removing noise, background, and distortions. The dimension of the input image is  $256 \times 256$  to reduce the training time. So we resized our image dataset to  $256 \times 256$  using the OpenCV 3.4.3 with Python 3.7 framework [26]. Further, the contrast of the apple leaf images is improved using the histogram equalization method [27] following Equation (3).

$$H(P_{(x,y)}) = \text{round} \left( \frac{f_{cdf}(p_{(x,y)}) - f_{cdf_{min}}}{(R \times C) - f_{cdf}} \times L - 1 \right). \quad (3)$$

Where,  $f_{cdf}$  = cumulative frequency,  $f_{cdf_{min}}$  = minimum value of cumulative function,  $f_{cdf}(p_{x,y})$  = intensity of current pixel,  $R \times C$  = product of the number of pixels in rows and columns, and  $L$  = number of intensities.

**3.4. MCNN Network Model.** Convolutional neural networks which are specifically designed to deal with 2D shapes were first introduced by Lecun et al. in 1998 [28]. The proposed multilayer convolutional neural network (MCNN) consists of convolution layers, batch normalization



layers, ReLU layers, max-pooling layers, and fully connected and softmax layers. The MCNN model has three blocks; the first block includes convolution, batch normalization, ReLU activation function, and max-pooling layers. The rest of the blocks include a convolution layer, ReLU function, max-pooling followed by a fully connected layer, and a softmax layer as shown in Figure 4.

The convolution operation was used to extract features such as color and edges from an apple leaf image. In this work, the size of the filter has been fixed in all the convolution layers, but the number of filters has been changed. In the first convolution layer, the number of filters is 8, while in the second and third convolution layers are 16 and 32 respectively. The main function of these layers is to extract properties from the input image. The batch normalization layer was used to speed up the training of multilayer convolutional neural networks and reduce the sensitivity for network initialization. Rectified Linear Unit (ReLU) activation function has been used to eliminate negative values, which can be represented by Equation (4) [29].

$$f(x) = \begin{cases} 0 & \text{for } x \leq 0 \\ x & \text{for } x > 0 \end{cases} = \max\{0, x\} = x1_{x > 0}. \quad (4)$$

The max-pooling layer contains parameters such as the number of filters and the number of step sizes, which were used to reduce samples by choosing the maximum value and excluding the remaining value. The features were extracted from convolution1, Relu1, max-polling1, convolution2, Relu2, max-polling2, convolution3, Relu3, max-polling3. The fully connected layer belongs to the three classes of apple leaf diseases in this work. The class number represents the number of neurons used to connect each input to all neurons. The softmax function has been used to calculate the probability of each target class with the range from 0 to 1. It returns the probabilities for each class and the target class, which have a more high probability.

In order to verify the performance, the proposed network is trained using the apple leaf disease identification dataset [30]. It includes a set of 5461 images of apple black root, apple cedar rust, and apple scab leaves. The proposed method is experimented with using Google Colab (Jupyter Notebook) deep learning framework with a single 12GB NVIDIA Tesla K80 GPU.

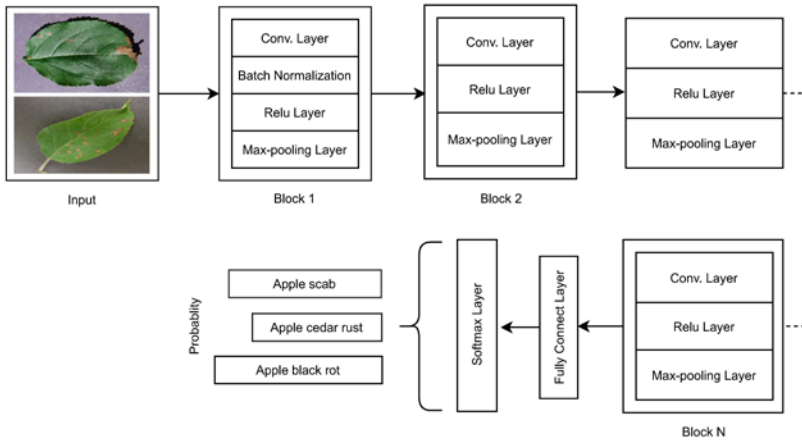


Fig. 4. The architecture of the proposed multilayer convolutional neural network

Other programming languages can be used such as Matlab, R, etc., to implement the proposed MCNN model. To train the MCNN network, the Adam optimizer [31] has been used with a batch size of 10 and 40 epochs. The training hyper-parameters used in this experiment are shown in Table 2.

Table 2. Training parameters of the proposed MCNN model

| Parameter       | Description                       |
|-----------------|-----------------------------------|
| Number of epoch | 40                                |
| Learning rate   | 1e-3                              |
| Batch Size      | 10                                |
| Steps           | 100                               |
| Optimizer       | Adam (adaptive moment estimation) |

**4. Results and Discussion.** This section discusses the results of the proposed method as part of the current research work. The performance of the proposed model is assessed by accuracy and confusion matrices are shown, and the necessary conclusions are drawn. The proposed MCNN model has achieved a training accuracy of 98.40% and a testing accuracy of 98.47%, with 0.05 training loss and 0.03 testing loss. The changes in training and testing loss, along with training and testing accuracy with respect to epochs, are shown in Figure 5. Accuracy is the number of accurate predictions regarding the total predictions made by a model.

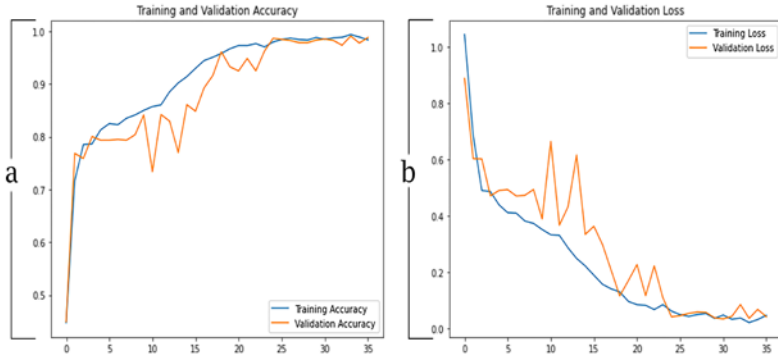


Fig. 5. Accuracy and loss graphs during model trainings: (a) training and validation accuracy; (b) training and validation loss

In addition, the performance of the MCNN model is shown using the Confusion Matrix Method (CMM) on the proposed dataset (Figure 6). The CMM method was applied to evaluate the classification accuracy for each class. The proposed MCNN model correctly predicts an average of 90 images out of 100 images. Also, the CMM method can be used to find the True Positive and False Positive Rates according to Equation (5) and Equation (6) [32].

$$\text{True Positive Rate} = \frac{\text{True Positives}}{\text{True Positives} + \text{False Negatives}} \times 100\% , \quad (5)$$

$$\text{False Positive Rate} = \frac{\text{True Positives}}{\text{True Positives} + \text{True Negatives}} \times 100\% . \quad (6)$$

From Table 3, it can be observed that the proposed MCNN model achieved 98.47% testing accuracy, which is more than the testing accuracies in the research works done by Khamparia et al. [33], with a testing accuracy of 86.78%, Tiwari et al. [34], with a testing accuracy of 97.8%, and Mohameth et al. [35], with a testing accuracy of 98%. The testing accuracy of the proposed model is slightly lesser than the testing accuracies in the research works done by Ferentinos [36] with a testing accuracy of 99.5%. However, in the proposed work only 688,315 training parameters are used, which is much less as compared to the number of training parameters in the state-of-the-art systems. The proposed model can be used for automatic plant disease detection on low computational power systems with less training time and prediction time.




Fig. 6. Confusion Matrix for proposed MCNN model

Table 3. Comparison of different state-of-the-arts with the proposed model

| Author's name and year  | Proposed approach             | Testing accuracy | Training parameters |
|-------------------------|-------------------------------|------------------|---------------------|
| Proposed approach       | MCNN                          | 98.47%           | 688,315             |
| Khamparia et al. (2020) | Convolutional Encoder Network | 86.78%           | 3.3 million         |
| Tiwari et al. (2020)    | VGG-19 + SVM                  | 97.8%            | 143 million         |
| Mohameth et al. (2020)  | ResNet-50 + SVM               | 98%              | 25 million          |
| Ferentinos (2018)       | VGGNet                        | 99.5%            | 138 million         |

**5. Conclusion.** This paper has presented an automated apple leaf disease classification using a multilayer convolutional neural network model. The MCNN model uses apple leaf images to determine the existence of disease with the highest detection rate of apple leaves. The proposed model encompasses the OpenCV crop method and histogram equalization method based on image preprocessing, affine transformation and perspective transformation-based augmentation, adaptive moment estimation-based parameter optimization, and MCNN-based classification.

The experimental outcome has shown the higher performance of this work compared to other methods. Also, acceptable results have been achieved. It's indicated that deep learning is a significant method for leaf disease classification.

In the future, the detection efficiency of the MCNN method will be improved by the utilization of advanced deep learning-based image classification techniques with a web application for a real-time disease monitoring system. Additionally, we intend to expand our dataset to include more apple leaf images in order to build better models for the future.

## References

1. A.I. Kuzin, N.Ya. Kashirskaya, A.M. Kochkina, and A.V. Kushner, "Correction of Potassium Fertigation Rate of Apple Tree (*Malus domestica* Borkh.) in Central Russia during the Growing Season," *Plants*, vol. 9, no. 10, p. 1366, Oct. 2020, doi: 10.3390/plants9101366.
2. A.P. K. Tai, M.V. Martin, and C.L. Heald, "Threat to future global food security from climate change and ozone air pollution," *Nature Clim Change*, vol. 4, no. 9, pp. 817–821, Sep. 2014, doi: 10.1038/nclimate2317.
3. R.N. Strange and P.R. Scott, "Plant Disease: A Threat to Global Food Security," *Annu. Rev. Phytopathol.*, vol. 43, no. 1, pp. 83–116, Sep. 2005, doi: 10.1146/annurev.phyto.43.113004.133839.
4. K.R. Aravind, P. Raja, K.V. Mukesh, R. Anirudh, R. Ashiwin, and C. Szczepanski, "Disease classification in maize crop using bag of features and multiclass support vector machine," in 2018 2nd International Conference on Invention Systems and Control (ICISC), Coimbatore, Jan. 2018, pp. 1191–1196. doi: 10.1109/ICISC.2018.8398993.
5. V.P. Kour and S. Arora, "Particle Swarm Optimization Based Support Vector Machine (P-SVM) for the Segmentation and Classification of Plants," *IEEE Access*, vol. 7, pp. 29374–29385, 2019, doi: 10.1109/ACCESS.2019.2901900.
6. M. Sheikhan, M. Pezhmanpour, and M.S. Moin, "Improved contourlet-based steganalysis using binary particle swarm optimization and radial basis neural networks," *Neural Comput & Applic*, vol. 21, no. 7, pp. 1717–1728, Oct. 2012, doi: 10.1007/s00521-011-0729-9.
7. N. Guettari, A.S. Capelle-Laize, and P. Carre, "Blind image steganalysis based on evidential K-Nearest Neighbors," in 2016 IEEE International Conference on Image Processing (ICIP), Phoenix, AZ, USA, Sep. 2016, pp. 2742–2746. doi: 10.1109/ICIP.2016.7532858.
8. P. Bedi and P. Gole, "Plant disease detection using hybrid model based on convolutional autoencoder and convolutional neural network," *Artificial Intelligence in Agriculture*, vol. 5, pp. 90–101, 2021, doi: 10.1016/j.iaia.2021.05.002.
9. S. Chakraborty, S. Paul, and Md. Rahat-uz-Zaman, "Prediction of Apple Leaf Diseases Using Multiclass Support Vector Machine," in 2021 2nd International Conference on Robotics, Electrical and Signal Processing Techniques (ICREST), DHAKA, Bangladesh, Jan. 2021, pp. 147–151. doi: 10.1109/ICREST51555.2021.9331132.
10. Y. Zhong and M. Zhao, "Research on deep learning in apple leaf disease recognition," *Computers and Electronics in Agriculture*, vol. 168, p. 105146, Jan. 2020, doi: 10.1016/j.compag.2019.105146.
11. P. Jiang, Y. Chen, B. Liu, D. He, and C. Liang, "Real-Time Detection of Apple Leaf

- Diseases Using Deep Learning Approach Based on Improved Convolutional Neural Networks,” *IEEE Access*, vol. 7, pp. 59069–59080, 2019, doi: 10.1109/ACCESS.2019.2914929.
12. A.M. Hashan, E. Agbozo, A.A.K. Al-Saeedi, S. Saha, A. Haidari, and M.N.F. Rabi, “Brain Tumor Detection in MRI Images Using Image Processing Techniques,” in 2021 4th International Symposium on Agents, Multi-Agent Systems and Robotics (ISAMSR), Batu Pahat, Malaysia, Sep. 2021, pp. 24–28. doi: 10.1109/ISAMSR53229.2021.9567799.
  13. A.K. Rangarajan, R. Purushothaman, and A. Ramesh, “Tomato crop disease classification using pre-trained deep learning algorithm,” *Procedia Computer Science*, vol. 133, pp. 1040–1047, 2018, doi: 10.1016/j.procs.2018.07.070.
  14. X. Xie, Y. Ma, B. Liu, J. He, S. Li, and H. Wang, “A Deep-Learning-Based Real-Time Detector for Grape Leaf Diseases Using Improved Convolutional Neural Networks,” *Front. Plant Sci.*, vol. 11, p. 751, Jun. 2020, doi: 10.3389/fpls.2020.00751.
  15. J. Sun, Y. Yang, X. He, and X. Wu, “Northern Maize Leaf Blight Detection Under Complex Field Environment Based on Deep Learning,” *IEEE Access*, vol. 8, pp. 33679–33688, 2020, doi: 10.1109/ACCESS.2020.2973658.
  16. H. Sabrol and K. Satish, “Tomato plant disease classification in digital images using classification tree,” in 2016 International Conference on Communication and Signal Processing (ICCSPP), Melmaruvathur, Tamilnadu, India, Apr. 2016, pp. 1242–1246. doi: 10.1109/ICCSPP.2016.7754351.
  17. D. Yadav, Akanksha, and A.K. Yadav, “A Novel Convolutional Neural Network Based Model for Recognition and Classification of Apple Leaf Diseases,” *TS*, vol. 37, no. 6, pp. 1093–1101, Dec. 2020, doi: 10.18280/ts.370622.
  18. S. Baranwal, S. Khandelwal, and A. Arora, “Deep Learning Convolutional Neural Network for Apple Leaves Disease Detection,” *SSRN Journal*, 2019, doi: 10.2139/ssrn.3351641.
  19. B. Liu, Y. Zhang, D. He, and Y. Li, “Identification of Apple Leaf Diseases Based on Deep Convolutional Neural Networks,” *Symmetry*, vol. 10, no. 1, p. 11, Dec. 2017, doi: 10.3390/sym10010011.
  20. M. Kerkech, A. Hafiane, and R. Canals, “Vine disease detection in UAV multispectral images using optimized image registration and deep learning segmentation approach,” *Computers and Electronics in Agriculture*, vol. 174, p. 105446, Jul. 2020, doi: 10.1016/j.compag.2020.105446.
  21. S.L. Sanga, D. Machuve, and K. Jomanga, “Mobile-based Deep Learning Models for Banana Disease Detection,” *Eng. Technol. Appl. Sci. Res.*, vol. 10, no. 3, pp. 5674–5677, Jun. 2020, doi: 10.48084/etasr.3452.
  22. Department of Computer Science, Sukkur IBA University, Pakistan. et al., “Plant Disease Detection using Deep Learning,” *IJRTE*, vol. 9, no. 1, pp. 909–914, May 2020, doi: 10.35940/ijrte.A2139.059120.
  23. L. Wu, J. Ma, Y. Zhao, and H. Liu, “Apple Detection in Complex Scene Using the Improved YOLOv4 Model,” *Agronomy*, vol. 11, no. 3, p. 476, Mar. 2021, doi: 10.3390/agronomy11030476.
  24. S. Coulibaly, B. Kamsu-Foguem, D. Kamissoko, and D. Traore, “Deep neural networks with transfer learning in millet crop images,” *Computers in Industry*, vol. 108, pp. 115–120, Jun. 2019, doi: 10.1016/j.compind.2019.02.003.
  25. F. Brill, V. Erukhimov, R. Giduthuri, and S. Ramm, “Basic image transformations,” in *OpenVX Programming Guide*, Elsevier, 2020, pp. 85–123. doi: 10.1016/B978-0-12-816425-9.00012-7.
  26. S. Gollapudi, “OpenCV with Python,” in *Learn Computer Vision Using OpenCV*, Berkeley, CA: Apress, 2019, pp. 31–50. doi: 10.1007/978-1-4842-4261-2\_2.
  27. H. Ali, M.I. Lali, M.Z. Nawaz, M. Sharif, and B.A. Saleem, “Symptom based

- automated detection of citrus diseases using color histogram and textural descriptors,” *Computers and Electronics in Agriculture*, vol. 138, pp. 92–104, Jun. 2017, doi: 10.1016/j.compag.2017.04.008.
28. Y. Lecun, L. Bottou, Y. Bengio, and P. Haffner, “Gradient-based learning applied to document recognition,” *Proc. IEEE*, vol. 86, no. 11, pp. 2278–2324, Nov. 1998, doi: 10.1109/5.726791.
29. A.F. Agarap, “Deep Learning using Rectified Linear Units (ReLU),” arXiv:1803.08375 [cs, stat], Feb. 2019, Accessed: Dec. 13, 2021. [Online]. Available: <http://arxiv.org/abs/1803.08375>
30. Antor Mahamudul Hashan, “Apple Leaf Diseases.” Kaggle. doi: 10.34740/KAGGLE/DSV/2068940.
31. D.P. Kingma and J. Ba, “Adam: A Method for Stochastic Optimization,” 2014, doi: 10.48550/ARXIV.1412.6980.
32. R.R.O. Al-Nima, S.S. Dlay, W.L. Woo, and J.A. Chambers, “A novel biometric approach to generate ROC curve from the Probabilistic Neural Network,” in *2016 24th Signal Processing and Communication Application Conference (SIU)*, Zonguldak, Turkey, May 2016, pp. 141–144. doi: 10.1109/SIU.2016.7495697.
33. A. Khamparia, G. Saini, D. Gupta, A. Khanna, S. Tiwari, and V.H.C. de Albuquerque, “Seasonal Crops Disease Prediction and Classification Using Deep Convolutional Encoder Network,” *Circuits Syst Signal Process*, vol. 39, no. 2, pp. 818–836, Feb. 2020, doi: 10.1007/s00034-019-01041-0.
34. D. Tiwari, M. Ashish, N. Gangwar, A. Sharma, S. Patel, and S. Bhardwaj, “Potato Leaf Diseases Detection Using Deep Learning,” in *2020 4th International Conference on Intelligent Computing and Control Systems (ICICCS)*, Madurai, India, May 2020, pp. 461–466. doi: 10.1109/ICICCS48265.2020.9121067.
35. F. Mohameth, C. Bingcai, and K.A. Sada, “Plant Disease Detection with Deep Learning and Feature Extraction Using Plant Village,” *JCC*, vol. 08, no. 06, pp. 10–22, 2020, doi: 10.4236/jcc.2020.86002.
36. K.P. Ferentinos, “Deep learning models for plant disease detection and diagnosis,” *Computers and Electronics in Agriculture*, vol. 145, pp. 311–318, Feb. 2018, doi: 10.1016/j.compag.2018.01.009.

**Mahamudul Hashan Antor** — Ph.D., Teacher assistant, Institute of fundamental education, Ural Federal University (UrFU). Research interests: intelligent information technologies; design, development and application of innovative software systems. The number of publications — 7. [mantor@urfu.ru](mailto:mantor@urfu.ru); 19, Mira St., 620002, Yekaterinburg, Russia; office phone: +7(962)316-1100.

**Md Rakib Ul Islam Rizu** — Graduate student, Ural Federal University (UrFU). Research interests: deep learning, machine learning. [mdrakibulislam.rizu@urfu.me](mailto:mdrakibulislam.rizu@urfu.me); 19, Mira St., 620002, Yekaterinburg, Russia; office phone: +7(965)545-09-44.

**Avinash Kumar** — Graduate student, Department of computer science, Ural Federal University (UrFU). Research interests: deep learning, machine learning. [avinash.kumar@urfu.me](mailto:avinash.kumar@urfu.me); 19, Mira St., 620002, Yekaterinburg, Russia; office phone: +7(919)397-64-01.

А. МАХМУДУЛ ХАСАН, Р. МД РАКИБ УЛ ИСЛАМ, К. АВИНАШ  
**КЛАССИФИКАЦИЯ БОЛЕЗНЕЙ ЛИСТЬЕВ ЯБЛОНИ С  
ИСПОЛЬЗОВАНИЕМ НАБОРА ДАННЫХ ИЗОБРАЖЕНИЙ:  
ПОДХОД МНОГОСЛОЙНОЙ СВЕРТОЧНОЙ НЕЙРОННОЙ  
СЕТИ**

*Махмудул Хасан А., Мд Ракиб Ул Ислам Р., Авинаш К. Классификация болезней листьев яблони с использованием набора данных изображений: подход многослойной сверточной нейронной сети.*

**Аннотация.** Сельское хозяйство является одним из основных источников экономического роста в России; мировое производство яблок в 2019 году составило 87 миллионов тонн. Болезни листьев яблони являются основной причиной ежегодного сокращения производства яблок, что приводит к огромным экономическим потерям. Автоматизированные методы выявления болезней листьев яблони позволяют сократить трудоемкую работу по мониторингу яблоневых садов и раннему выявлению симптомов болезни. В этой статье предложена многослойная сверточная нейронная сеть (MCNN), которая способна классифицировать листья яблони по одной из следующих категорий: парша яблони, черная гниль и болезни яблоневой кедровой ржавчины, используя недавно созданный набор данных. В этом методе мы использовали методы аффинного преобразования и перспективного преобразования для увеличения размера набора данных. После этого операции предварительной обработки на основе метода кадрирования и выравнивания гистограммы OpenCV использовались для улучшения предлагаемого набора данных изображения. Экспериментальные результаты показывают, что система достигает точности обучения 98,40% и точности проверки 98,47% для предложенного набора данных изображения с меньшим количеством параметров обучения. Результаты предполагают более высокую точность классификации предложенной модели MCNN по сравнению с другими известными современными подходами. Эта предложенная модель может использоваться для обнаружения и классификации других типов болезней яблони из разных наборов данных изображений.

**Ключевые слова:** искусственный интеллект, болезнь листьев яблони, обработка изображений, многослойная сверточная нейронная сеть, классификация.

### Литература

1. А.И. Кузин, Н.Я. Каширская, Кочкина А.М., Кушнер А.В. Коррекция нормы калийной фертигации яблони (*Malus domestica* Borkh.) в средней полосе России в период вегетации // Растения. 9, нет. 10, с. 1366, октябрь 2020 г., doi: 10.3390/plants9101366.
2. Тай А.П.К., Мартин М.В. и Хилд С.Л. Угроза будущей глобальной продовольственной безопасности от изменения климата и загрязнения воздуха озоном // Nature Clim Change. 4, нет. 9, стр. 817–821, сентябрь 2014 г., doi: 10.1038/nclimate2317.
3. Р.Н. Стрэндж и П.Р. Скотт, «Болезни растений: угроза глобальной продовольственной безопасности», Annu. Преподобный Phytopathol., vol. 43, нет. 1. С. 83–116, сентябрь 2005 г., doi: 10.1146/annurev.phyto.43.113004.133839.
4. Аравинд К.Р., Раджа П., Мукеш К.В., Анируд Р., Ашивин Р. и Щепански К., «Классификация болезней кукурузы с использованием набора признаков и многоклассовой машины опорных векторов», 2-я Международная конференция



- по изобретательским системам, 2018 г. and Control (ICISC), Coimbatore, январь 2018 г., стр. 1191–1196. doi: 10.1109/ICISC.2018.8398993.
5. В.П. Кур и С. Арора, «Машина опорных векторов на основе оптимизации роя частиц (P-SVM) для сегментации и классификации растений», IEEE Access, vol. 7, стр. 29374–29385, 2019, doi: 10.1109/ACCESS.2019.2901900.
  6. М. Шейхан, М. Пежманпур, М.С. Мойн, «Улучшенный стегоанализ на основе контурлетов с использованием оптимизации роя бинарных частиц и радиальных нейронных сетей», Neural Comput & Applic, vol. 21, нет. 7, стр. 1717–1728, октябрь 2012 г., doi: 10.1007/s00521-011-0729-9.
  7. Н. Геттари, А.С. Капелле-Лэиз и П. Карре, «Слепой стегоанализ изображений на основе доказательных К-ближайших соседей», Международная конференция IEEE по обработке изображений (ICIP), 2016 г., Феникс, Аризона, США, сентябрь 2016 г., стр. 2742–2746. doi: 10.1109/ICIP.2016.7532858.
  8. Беди П. и Голе П. Обнаружение болезней растений с использованием гибридной модели на основе сверточных автоэнкодеров и сверточных нейронных сетей // Искусственный интеллект в сельском хозяйстве. 5, стр. 90–101, 2021, doi: 10.1016/j.aiaa.2021.05.002.
  9. С. Чакраборти, С. Пол и доктор медицинских наук Рахат-уз-Заман, «Прогнозирование болезней листьев яблони с использованием мультиклассовой машины опорных векторов», 2-я Международная конференция по робототехнике, электрическим технологиям и методам обработки сигналов (ICREST), 2021 г., Бангладеш, январь 2021 г., стр. 147–151. doi: 10.1109/ICREST51555.2021.9331132.
  10. Ю. Чжун и М. Чжао, «Исследование глубокого обучения в распознавании болезней листьев яблони», Компьютеры и электроника в сельском хозяйстве, том. 168, с. 105146, январь 2020 г., doi: 10.1016/j.compag.2019.105146.
  11. П. Йианг, Ы. Цхен, Б. Лиу, Д. Хе и Ц. Лианг, «Обнаружение болезней листьев яблони в реальном времени с использованием подхода глубокого обучения, основанного на улучшенных сверточных нейронных сетях», IEEE Access, vol. 7, стр. 59069–59080, 2019, doi: 10.1109/ACCESS.2019.2914929.
  12. А.М. Хасан, Э. Агбозо, А.А.К. Аль-Саиди, С. Саха, А. Хайдари и М.Н.Ф. Раби, «Обнаружение опухоли головного мозга на изображениях МРТ с использованием методов обработки изображений», в 2021 г. 4-й Международный симпозиум по агентам, многоагентным Системам и робототехника (ISAMSR), Бату Пахат, Малайзия, сентябрь 2021 г., стр. 24–28. doi: 10.1109/ISAMSR53229.2021.9567799.
  13. А.К. Рангараджан, Р. Пурушотаман и А. Рамеш, «Классификация болезней растений томатов с использованием предварительно обученного алгоритма глубокого обучения», Procedia Computer Science, vol. 2018. Т. 133. С. 1040–1047. doi: 10.1016/j.procs.2018.07.070.
  14. Х. Хие, Ы. Ма, Б. Лиу, Дж. Хе, С. Ли и Х. Щанг, «Детектор заболеваний виноградных листьев в режиме реального времени на основе глубокого обучения с использованием усовершенствованных сверточных нейронных сетей», Front. Растениевод., т. 1, с. 11, с. 751, июнь 2020 г., doi: 10.3389/fpls.2020.00751.
  15. Дж. Сан, Ы. Бланг, Х. Хе и Х. Шу, «Обнаружение гнили листьев северной кукурузы в сложных полевых условиях на основе глубокого обучения», IEEE Доступ, том. 8, стр. 33679–33688, 2020, doi: 10.1109/ACCESS.2020.2973658.
  16. Х. Саброл и К. Сатни, «Классификация болезней растений томатов на цифровых изображениях с использованием дерева классификации», Международная конференция по связи и обработке сигналов (ICCSF) 2016 г., Мелмаруватур, Тамилнаду, Индия, апрель 2016 г., стр. 1242– 1246. doi:

- 10.1109/ICCCSP.2016.7754351.
17. Д. Ядав, Аканкша и А.К. Ядав, «Новая модель на основе сверточной нейронной сети для распознавания и классификации болезней листьев яблоны», TS, vol. 37, нет. 6, стр. 1093–1101, декабрь 2020 г., doi: 10.18280/ts.370622.
  18. С. Баранвал, С. Ханделвал и А. Арора, «Сверточная нейронная сеть с глубоким обучением для обнаружения болезней листьев яблоны», SSRN Journal, 2019, doi: 10.2139/ssrn.3351641.
  19. Лю Б., Чжан Ю., Хе Э., Ли Ю., «Идентификация болезней листьев яблоны на основе глубоких сверточных нейронных сетей», Симметрия, том. 10, нет. 1, с. 11 декабря 2017 г., doi: 10.3390/sym10010011.
  20. М. Керкеч, А. Хафиз и Р. Каналс, «Обнаружение болезней винограда на многоспектральных изображениях БПЛА с использованием оптимизированной регистрации изображений и подхода к сегментации глубокого обучения», Компьютеры и электроника в сельском хозяйстве, том. 174, с. 105446, июль 2020 г., doi: 10.1016/j.compag.2020.105446.
  21. С.Л. Санга, Д. Мачуве и К. Джоманга, «Мобильные модели глубокого обучения для обнаружения банановых болезней», Eng. Технол. заявл. науч. Рез., том. 10, нет. 3, стр. 5674–5677, июнь 2020 г., doi: 10.48084/etasr.3452.
  22. Факультет компьютерных наук, Университет Сукукур ИВА, Пакистан и др., «Обнаружение болезней растений с использованием глубокого обучения», IJRTE, vol. 9, нет. 1, стр. 909–914, май 2020 г., doi: 10.35940/ijrte.A2139.059120.
  23. Л. Ву, Дж. Ма, Ю. Чжао и Х. Лю, «Обнаружение яблок в сложной сцене с использованием улучшенной модели YOLOv4», Агрономия, том. 11, нет. 3, с. 476, март 2021 г., doi: 10.3390/agronomy11030476.
  24. С. Кулибали, Б. Камусу-Фогем, Д. Камиссоко и Д. Траоре, «Глубокие нейронные сети с переносом обучения на изображениях урожая проса», Компьютеры в промышленности, том. 108, стр. 115–120, июнь 2019 г., doi: 10.1016/j.compind.2019.02.003.
  25. Брилл Ф., Ерухимов В., Гидутури Р., Рамм С., «Основные преобразования изображений», в Руководстве по программированию OpenVX, Elsevier, 2020, стр. 85–123. doi: 10.1016/B978-0-12-816425-9.00012-7.
  26. С. Голлапуди, «OpenCV с Python», в книге «Изучение компьютерного зрения с помощью OpenCV», Беркли, Калифорния: Apress, 2019, стр. 31–50. doi: 10.1007/978-1-4842-4261-2\_2.
  27. Али Х., Лали М.И., Наваз М.З., Шариф М. и Салим Б.А. Автоматическое обнаружение болезней цитрусовых на основе симптомов с использованием цветовой гистограммы и текстурных дескрипторов // Компьютеры и электроника в сельском хозяйстве. 138, стр. 92–104, июнь 2017 г., doi: 10.1016/j.compag.2017.04.008.
  28. Ю. Лекун, Л. Ботту, Ю. Бенжио и П. Хаффнер, «Градиентное обучение, применяемое для распознавания документов», Proc. IEEE, том. 86, нет. 11, стр. 2278–2324, ноябрь 1998 г., doi: 10.1109/5.726791.
  29. Агарал А.Ф., «Глубокое обучение с использованием выпрямленных линейных единиц (ReLU)», arXiv: 1803.08375 [cs, stat], февраль 2019 г., доступ: 13 декабря 2021 г. [Онлайн]. Доступно: <http://arxiv.org/abs/1803.08375>
  30. Антор Махмудул Хасан, «Болезни листьев яблоны». Каггль. doi: 10.34740/KAGGLE/DSV/2068940.
  31. Д.П. Кингма и Дж.Ба, «Адам: метод стохастической оптимизации», 2014 г., doi: 10.48550/ARXIV.1412.6980.
  32. Р.Р.О. Аль-Нима, С.С. Длей, У.Л. Ву и Дж.А. Чемберс, «Новый биометрический подход к созданию ROC-кривой на основе вероятностной нейронной сети», 24-я конференция по обработке сигналов и связи (SIU), Зонгулдак, Турция, 2016 г.

- Май 2016 г., стр. 141–144. doi: 10.1109/SIU.2016.7495697.
33. А. Хампария, Г. Саини, Д. Гупта, А. Ханна, С. Тивари и В.Х.К. де Альбукерке, «Прогнозирование и классификация сезонных болезней сельскохозяйственных культур с использованием сети глубоких сверточных кодировщиков», *Circuits Syst Signal Process*, vol. 39, нет. 2, стр. 818–836, февраль 2020 г., doi: 10.1007/s00034-019-01041-0.
  34. Д. Тивари, М. Ашиш, Н. Гангвар, А. Шарма, С. Патель и С. Бхардвадж, «Обнаружение болезней листьев картофеля с использованием глубокого обучения», 2020 г. 4-я Международная конференция по интеллектуальным вычислительным системам и системам управления (ICICCS), Мадурай, Индия, май 2020 г., стр. 461–466. doi: 10.1109/ICICCS48265.2020.9121067.
  35. Ф. Мохамет, К. Бинкай и К.А. Сада, «Обнаружение болезней растений с помощью глубокого обучения и извлечения признаков с использованием Plant Village», *JCC*, vol. 08, нет. 06, стр. 10–22, 2020, doi: 10.4236/jcc.2020.86002.
  36. Ферентинос К.П. Модели глубокого обучения для обнаружения и диагностики болезней растений // *Компьютеры и электроника в сельском хозяйстве*. 145, стр. 311–318, февраль 2018 г., doi: 10.1016/j.compag.2018.01.009.

**Махмудул Хасан Антор** — Ph.D., помощник преподавателя, институт фундаментального образования, ФГАОУ ВО «УрФУ имени первого Президента России Б.Н. Ельцина» (УрФУ). Область научных интересов: интеллектуальные информационные технологии; проектирование, разработка и применение инновационных программных систем. Число научных публикаций — 7. mantor@urfu.ru; улица Мира, 19, 620002, Екатеринбург, Россия; р.т.: +7(962)316-1100.

**Мд Ракиб Ул Ислам Ризу** — студент, ФГАОУ ВО «УрФУ имени первого Президента России Б.Н. Ельцина» (УрФУ). Область научных интересов: глубокое обучение, машинное обучение. mdrakibulislam.rizu@urfu.me; улица Мира, 19, 620002, Екатеринбург, Россия; р.т.: +7(965)545-09-44.

**Авинаш Кумар** — студент, кафедра компьютерных наук, ФГАОУ ВО «УрФУ имени первого Президента России Б.Н. Ельцина» (УрФУ). Область научных интересов: глубокое обучение, машинное обучение. avinash.kumar@urfu.me; улица Мира, 19, 620002, Екатеринбург, Россия; р.т.: +7(919)397-64-01.

О.В. ДАРИНЦЕВ, А.Б. МИГРАНОВ  
**АНАЛИТИЧЕСКИЙ ОБЗОР ПОДХОДОВ К РАСПРЕДЕЛЕНИЮ  
ЗАДАЧ В ГРУППАХ МОБИЛЬНЫХ РОБОТОВ НА ОСНОВЕ  
ТЕХНОЛОГИЙ МЯГКИХ ВЫЧИСЛЕНИЙ.**

*Даринцев О.В., Мигранов А.Б. Аналитический обзор подходов к распределению задач в группах мобильных роботов на основе технологий мягких вычислений.*

**Аннотация.** Рассматривается использование различных типов эвристических алгоритмов на основе технологий мягких вычислений для распределения задач в группах мобильных роботов, выполняющих односложные операции в едином рабочем пространстве: генетические алгоритмы, муравьиные алгоритмы и искусственные нейронные сети. Показано, что данная задача является NP-сложной и ее решение прямым перебором для большого числа заданий невозможно. Исходная задача сведена к типовым NP-полным задачам: обобщенной задаче поиска оптимальной группы замкнутых маршрутов от одного депо и задаче коммивояжера. Представлены описание каждого из выбранных алгоритмов и сравнение их характеристик. Приводится пошаговый алгоритм работы с учетом выбранных генетических операторов и их параметров при заданном объеме популяции. Представлена общая структура разработанного алгоритма, позволяющего достаточно эффективно решить многокритериальную оптимизационную задачу с учетом временных затрат и интегрального критерия эффективности роботов, учитывающего энергетические затраты, функциональную насыщенность каждого агента группы и т.д. Показана возможность решения исходной задачи с использованием муравьиного алгоритма и обобщенного поиска оптимальной группы замкнутых маршрутов. Для многокритериальной оптимизации показана возможность линейной свертки полученного векторного критерия оптимальности за счет введения дополнительных параметров, характеризующих групповое управление: общее КПД функционирования всех роботов, затраты энергии на функционирование группы поддержки и энергия на размещение одного робота на рабочем поле. Для решения задачи распределения заданий с использованием нейронной сети Хопфилда произведено ее представление в виде графа, полученного в ходе перехода от обобщенной задачи поиска оптимальной группы замкнутых маршрутов от одного депо к задаче коммивояжера. Показателем качества выбран суммарный путь, пройденный каждым из роботов группы.

**Ключевые слова:** коллектив роботов, распределение задач, генетический алгоритм, муравьиный алгоритм, нейросеть Хопфилда.

**1. Введение.** Использование управляемых групп мобильных роботов является целесообразным во многих ситуациях, наиболее же явно их преимущество проявляется при работе в труднодоступной местности и опасных условиях эксплуатации. К примеру, использование мобильных роботов достаточно эффективно при контроле состояния сетей газо- и нефтепроводов [1, 2], при отслеживании лесных пожаров и стихийных бедствий [3, 4].

В связи с этим синтез алгоритмов квазиоптимального управления группами роботов при выполнении поставленной задачи

является одним из активно исследуемых направлений робототехники [5–7].

Более узкой задачей является задача построения оптимального алгоритма поведения группы роботов на рабочем поле с учетом наличия нескольких задач. Дополнительным критерием, усложняющим поиск решения данной задачи, является то, что это решение должно обеспечить управление при произвольном количестве задач и роботов.

В работе [8] проводится исследование возможности назначения ролей в группе роботов при ограниченных средствах коммуникаций. По сути это параллельная задача, в которой необходимо провести назначение заданий роботам только на один шаг. Авторы предлагают итерационный подход к распределению ролей в группе роботов, основанный на стратегии децентрализованного управления и принципах роевого взаимодействия.

В работе [9] на основе классического муравьиного алгоритма предложена новая методология для задач распределения роботов по заданиям. При этом рассматривается классическая задача MRTA (multi-robot task allocation): дано  $n$  роботов, каждый из которых способен выполнить одну задачу, и  $m$  возможных заданий, каждое из которых требует одного робота на выполнение. Обязательным в этом случае является наличие параметра эффективности для каждой из возможных пар робот–задача. И хотя муравьиный алгоритм позволил получить хорошие результаты по робастности для данной задачи (полиномиальная сложность решения –  $O(n^4)$ ), сама задача является более простой с точки зрения постановки. Рассматривается только распределение на один шаг и задается матрица эффективности решений до начала работы алгоритма.

По результатам проведенного анализа видно, что для поиска решений задач распределения, представленных в более простой формулировке, достаточно часто используются эвристические алгоритмы. При этом методики решения полной задачи для произвольного количества роботов и заданий, которые также могут меняться в процессе работы, в тематической литературе не приводятся.

Поэтому целью настоящей работы являются анализ сложности исходной задачи и выбор типа алгоритмов, которые могут быть использованы для эффективного решения данной задачи.

**2. Анализ типа решаемой задачи.** Проведем постановку исходной задачи и выделим ее особенности.

Имеется рабочее поле размером  $N \times N$ , на котором в произвольных узлах располагается  $n$  роботов с координатами  $(x_i, y_i, i \in [1, n])$  и  $m$  заданий с координатами заданий  $(x_j^*, y_j^*, j \in [1, m])$ .

Целью функционирования роботов является выполнение заданий, расположенных на рабочем поле, при этом в каждой клетке одновременно могут находиться только один робот и/или одно задание.

Роботы характеризуются четырьмя параметрами:

- энергопотребление при выполнении работы  $w_i^{FN}$ ,
- энергопотребление при перемещении  $w_i^{MV}$ ,
- скорость перемещения  $v_i$ ,
- энергия на ввод в эксплуатацию  $W_i^{ST}$ .

Показателем качества полученного решения является энергия, потребляемая группой роботов при выполнении поставленной группы заданий. Количественно показатель может быть представлен в следующем виде:

$$W_{\Sigma} = \sum_{i=1..n} (S_i w_i^{MV} + \tau_i w_i^{MV} + W_i^{ST}), \quad (1)$$

где  $S_i$  – расстояние, пройденное  $i$ -м роботом, а  $\tau_i$  – время, затраченное  $i$ -м роботом при выполнении группы заданий.

Расстояние в первом приближении может быть найдено как сумма евклидовых расстояний между соседними точками маршрута:

$$S_i = \sum_m S_m^i = \sum_m \sqrt{(x_m - x_{m-1})^2 + (y_m - y_{m-1})^2}. \quad (2)$$

Особенности задачи в текущей постановке:

- предполагаются произвольные количества роботов в группе и заданий на поле, что переводит поставленную задачу в общем случае в разряд NP-полных;

- используется показатель качества (энергетический фактор) (1), что позволяет оценить эффективность принятой тактики поведения группы;

- предъявляются жесткие требования к полноте информации о положении как роботов, так и заданий на рабочем поле.

Большое число роботов и заданий, выделяемых в рамках общей задачи, приводит к невозможности проведения поиска оптимального алгоритма распределения задач среди роботов полным перебором за приемлемое время, т.к. задача является NP-полной. Примерами близких по объему вычислений задач из класса NP-полных являются:

- 1) задача коммивояжера;
- 2) оптимальный раскрой (бумага, стальной прокат, отливка), оптимизация маршрутов в воздушном пространстве;
- 3) составление расписаний, учитывающих определённые условия.

Рассматриваемая задача может быть представлена в виде графа и сведена к одной из классических NP-полных задач. Для перехода к графу необходимо и достаточно представить всю группу роботов и заданий на поле в виде вершин графа.

Зададим смешанный граф  $G=\{V, A\}$ , где  $A$  – множество неориентированных ребер;  $V=\{R \cup W\}$  – объединение непересекающихся множеств вершин  $R$ , соответствующих роботам, и вершин  $W$ , соответствующих заданиям.

При этом в графе  $G$  подграф  $W$  является полным, а любая пара вершин из подмножества  $R$  не является соседней. Каждое ребро является взвешенным. Вес ребра  $w_{ij}^k$  определяет энергетические затраты соответствующего перехода, которые определяются направлением перехода (из вершины  $W_i$  в вершину  $W_j$ ) и классом робота ( $k$ ), выполняющего переход.

Граф, построенный для группы из двух роботов и 4 заданий, представлен на рисунке 1.




Рис. 1. Граф G для задачи с двумя роботами и четырьмя задачами

Учитывая специфику исходной постановки задачи, требуется определить порядок заданий для каждого робота таким образом, чтобы все задания были выполнены, и совокупный расход энергии был минимален. На графе это эквивалентно построению из каждой вершины подмножества  $R$  маршрутов, которые в совокупности должны охватывать все вершины графа  $G$ , не иметь смежных вершин и иметь минимальную сумму весов ребер.

После представления задачи на графе становится очевидным, что это характерно для обобщенной задачи VRP (Vehicle Routing Problem) класса – задачи комбинаторной оптимизации, в которой для парка однотипных транспортных средств (ТС) (в данном варианте - роботов) требуется определить оптимальный набор замкнутых маршрутов от единственного депо (начальная точка положения робота) до множества удаленных клиентов (заданий). На практике критерий оптимальности может выражаться любыми затратами на объезд клиентов, но чаще всего используется длина маршрута.

Обобщение задачи VRP связано с различными типами роботов Heterogeneous VRP (HVRP) и с множеством депо Multi-Depot VRP (MDVRP) [10]. MDVRP – задача маршрутизации транспорта с несколькими депо [11]. HVRP – задача маршрутизации транспорта с разнородным парком [12], в которой клиенты обслуживаются несколькими типами ТС с отличающимися характеристиками, такими как: грузоподъемность, скорость, стоимость использования и т.п.

Как NP-полная задача, задача VRP может быть сведена к любой другой задаче вышеперечисленных классов. В большинстве случаев тестирование и использование алгоритмов решения NP-полных задач проводится для решения TSP (Traveling Salesman Problem, задача коммивояжера), поэтому проведем переход от VRP к TSP задаче.

Для перехода от полученной задачи VRP класса к задаче TSP класса необходимо ввести фиктивные переходы от задач к роботам и между узлами роботов (с нулевым весом). Также конец пути  $i$ -го робота (последнее задание для данного робота) необходимо замкнуть через фиктивный путь на  $i+1$  робота, а вершину  $n$ -го маршрута - на вершину первого робота.

В результате выполненных преобразований будет получен гамильтонов цикл – одно из возможных (не обязательно оптимальное) решение TSP. Примеры гамильтоновых циклов для рассматриваемой задачи показаны на рисунке 2.



Далее будут рассмотрены алгоритмы, использующие технологии мягких вычислений, и оценена сложность решаемой задачи с их использованием.

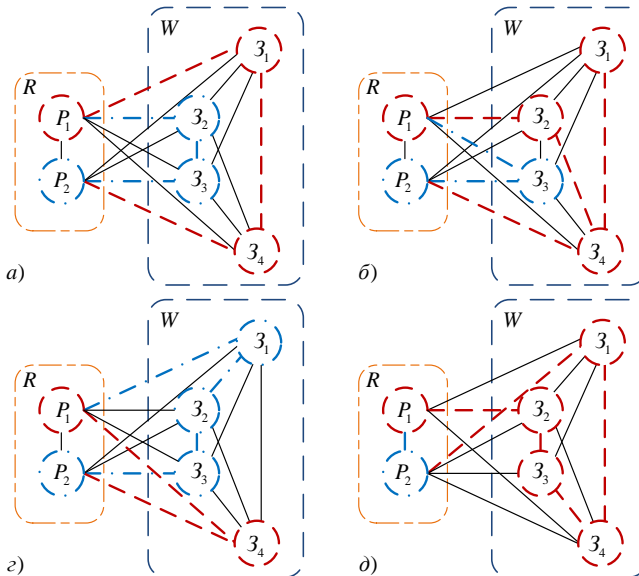


Рис. 2. Примеры гамильтоновых циклов (маршрутов-решений) на графе G для задачи с двумя роботами и четырьмя задачами

**3. Алгоритмы решения NP-задач.** Оценим сложность решения поставленной задачи при использовании алгоритма полного перебора. Для этого применим формулу оценки размера пространства поиска для задачи VRP (к которой удалось свести исходную задачу) с множественным депо и разнородным парком [13]:

$$N_{\text{VRP}} = \frac{(m+n-1)!}{(n-1)!}, \quad (3)$$

где  $n$  – число депо (в нашем случае число роботов в группе);  $m$  – число потребителей (заданий на поле).

Видно, что количество вершин-заданий определяет факториальный рост числа решений и в большей мере влияет на размер пространства поиска, нежели количество роботов. Разницу в размере пространств поиска в поставленной задаче распределения

заданий в рамках группы роботов при различных параметрах  $n$  и  $m$  легко оценить с помощью таблицы 1.

Таблица 1. Число возможных решений поставленной задачи при различном числе роботов ( $n$ ) и числе заданий ( $m$ )

| Параметры | $m = 2$ | $m = 3$ | $m = 5$ | $m = 10$       |
|-----------|---------|---------|---------|----------------|
| $n = 1$   | 2       | 6       | 120     | 3 628 800      |
| $n = 2$   | 6       | 24      | 720     | 39 916 800     |
| $n = 3$   | 12      | 60      | 2 520   | 239 500 800    |
| $n = 4$   | 20      | 120     | 6 720   | 1 037 836 800  |
| $n = 5$   | 30      | 210     | 15 120  | 3 632 428 800  |
| $n = 6$   | 42      | 336     | 30240   | 10 897 286 400 |
| $n = 7$   | 56      | 504     | 55440   | 29 059 430 400 |
| $n = 8$   | 72      | 720     | 95040   | 70 572 902 400 |

Отметим, что при числе заданий  $m > 66$  объем данных превышает предел Бремерманна [14] и задача становится трансвычислительной при любом возможном количестве роботов в группе.

Поэтому при решении NP-полных задач хорошо себя зарекомендовали технологии мягких вычислений, к которым также относятся «природные вычисления» (Natural Computing). Это научное направление, объединяющее методы с природными механизмами принятия решений, среди которых:

- Genetic Algorithms – генетические алгоритмы;
- Neural Network Computing – нейро-сетевые вычисления;
- Swarm Intelligence Algorithms – роевые алгоритмы.

Из роевых алгоритмов, в свою очередь, можно выделить:

- Ant Colony Algorithms – муравьиные алгоритмы;
- Artificial Bee Colony – алгоритмы пчелиного роя;
- Particle Swarm Optimization – алгоритм роя частиц.

В большинстве известных случаев NP-полные задачи решаются с использованием эвристических алгоритмов: роевых и генетических.

Сравнительный анализ роевых алгоритмов (пчелиного роя, муравьиного и роя частиц), приведенный в работах [15-17], позволяет выбрать наиболее эффективный из них – муравьиный алгоритм.

Выбор данного алгоритма вызван следующими преимуществами:

- наличие информации о положении заданий и роботов позволяет вычислить расстояние выбранного пути для конкретного

робота между активными точками на поле и анализировать эффективность данного решения,

- возможность представления исходной задачи в виде неориентированного взвешенного графа,

- необходимость выполнения всей группы заданий на поле близко по постановке с другой NP-полной задачей – задачей коммивояжера (TSR), именно для решения которой изначально разрабатывались и тестировались муравьиные алгоритмы [18-20].

Отдельным направлением поиска методов приближенного решения оптимизационных задач данного типа является использование нейросетей [21-25]. Отметим, что для оптимизации в основном используются сеть Хопфилда или ее модификации, которые имеют ряд преимуществ при решении подобных задач:

- 1) данная сеть не требует обучения, поэтому, как результат, нет необходимости иметь обширную базу данных по решениям для анализируемой задачи;

- 2) оптимизация рассматриваемой нейросети проводится на основании минимизации энергетической функции Ляпунова.

Далее более подробно рассмотрим применение выбранных типов алгоритмов для решения задачи распределения заданий в группе роботов.

**3.1.1. Муравьиный алгоритм.** Муравьиный алгоритм независимо от модификаций может быть представлен в виде следующих шагов при решении задачи TSP:

- 1) создание «муравьев» в исходных точках;
- 2) нахождение решения (путь от исходной точки к конечной);
- 3) обновление феромона;
- 4) выполнение дополнительных действий (специфических для рассматриваемой задачи);
- 5) если глобальное условие выхода из цикла не выполнено – повтор шагов 1–4.

Феромон при этом обеспечивает не прямой обмен информацией между внутренними циклами (разными генерациями «муравьев»). По сути это разнесенное во времени взаимодействие, при котором одна особь изменяет некоторую область окружающей среды, а другие используют эту информацию позже. Для построения муравьиного алгоритма, решающего поставленную проблему, необходимо выполнить следующие этапы:

- 1) представить задачу в виде набора компонент и переходов или набора неориентированных взвешенных графов, на которых муравьи могут строить решения;

- 2) выбрать специфический ACO (Ant Colony Optimization) алгоритм и применить его для решения задачи;
- 3) настроить параметры ACO-алгоритма.

Разновидностью ACO-алгоритма, которую успешно используют для решения VRP, является метод мультиколонийной муравьиной системы (Ant Multi-Colony Optimization, AMCO). Алгоритм имеет полиномиальную сложность ( $O(n^3)$ ), что позволяет эффективно применять его при решении задач большей размерности [26].

В основе AMCO заложена возможность совместного построения части решения одновременно несколькими колониями муравьев. Изначально формируются группы муравьев, включающие по одному представителю от каждой колонии. Каждая такая группа является заменой одного муравья в классическом варианте алгоритма. Муравьи группы в результате случайной генерации последовательно формируют решение, включая вершины в собственные маршруты на каждом шаге в порядке, определяемом вероятностно на основе объединенного множества альтернатив.

Муравей в группе  $k$ , принадлежащий колонии  $x$ , включает в свою часть решения вершину  $i$  на итерации  $t$  с нормализованной вероятностью [27]:

$$p_{x,i}^k(t) = \frac{[\tau_{x,i}^k(t)]^\alpha \times [\eta_{x,i}^k]^\beta}{\sum_{y \in Y} \sum_{j \in J^k} [\tau_{x,j}^k(t)]^\alpha \times [\eta_{x,j}^k]^\beta}, \quad (4)$$

где  $Y$  – множество колоний;  $J^k$  – множество доступных вершин для группы  $k$ ;  $\eta_{x,i}^k$  – априорная привлекательность альтернативы, обратная энергии перехода из текущей вершины муравья группы  $k$  колонии  $x$  в вершину  $i$ ;  $\tau_{x,i}^k$  – апостериорная эффективность альтернативы, определяемая количеством феромона колонии  $x$  на переходе из текущей вершины муравья группы  $k$  колонии  $x$  в вершину  $i$ ;  $\alpha$ ,  $\beta$  – настраиваемые параметры алгоритма.

Решение для колонии считается сформированным, если множество вершин (заданий) окажется пустым, то есть все вершины будут посещены (либо муравьем данной колонии, либо любыми другими муравьями из параллельных колоний). После каждого решения происходит увеличение количества феромона на дугах, использованных соответствующими колониями, обратно пропорционально суммарному весу всех дуг решения:

$$\Delta\tau_{x,i}^k(t) = \begin{cases} \frac{Q}{L_{x,k}(t)}, & \text{если } (i,j) \in T_{x,k}(t), \\ 0, & \text{в обратном случае,} \end{cases} \quad (5)$$

где  $T_{x,k}(t)$  – маршрут, пройденный муравьем  $k$  колонии  $x$  на итерации  $t$ ;  $L_{x,k}(t)$  – длина этого маршрута;  $Q$  – регулируемый параметр, значение которого выбирается одного порядка с длиной оптимального маршрута.

Затем традиционным образом происходит частичное повсеместное испарение феромона:

$$\tau_{x,i}(t+1) = (1-\rho) \times \tau_{x,i}(t) + \Delta\tau_{x,i}(t), \quad (6)$$

где  $\Delta\tau_{x,i}(t) = \sum_{k=1}^b \Delta\tau_{x,i}^k(t)$ ,  $b$  – количество муравьев в колонии  $x$ .

Оценка эффективности переходов по дугам графа проводится с помощью расчета суммарной энергии по формуле (1). Конечной точкой маршрута муравья считается точка последней вершины. В работе [28] для многокритериальной оптимизации проведена линейная свертка полученного векторного критерия оптимальности за счет введения дополнительных параметров, характеризующих групповое управление: общее КПД функционирования всех роботов, удельная энергия на функционирование группы поддержки и энергия на размещение одного робота на рабочем поле.

В результате для запуска АМСО требуется установить значения для следующего набора параметров:

- $t$  – количество итераций;
- $g$  – количество межколониальных групп муравьев;
- $\alpha$  – вес концентрации феромона дуг;
- $\beta$  – вес эвристической привлекательности дуг;
- $\rho$  – коэффициент испарения феромона.

**3.1.2. Численные эксперименты.** Рассмотрим группу из двух роботов. Роботы должны выполнить четыре задания. Рабочее пространство представляет собой поле размером  $10 \times 10$  клеток. Исходные данные для рассматриваемого примера приведены в таблице 2. Расположение роботов и заданий на поле представлено на рисунке 3.

Таблица 2. Параметры роботов и заданий на поле

| Роботы  |         |        |        |        |
|---|---------|--------|--------|--------|
| №   | 1       | 2      |        |        |
| Координаты  | {4, 10} | {1, 7} |        |        |
| Скорость $v_i$ , ед.раст./ед.врем   | 30      | 20     |        |        |
| Энергия на ввод в эксплуатацию $W_i^{ST}$ , ед.энерг.                     | 60      | 40     |        |        |
| Расход энергии на перемещение $w_i^{MV}$ , ед.энерг./ед.раст.             | 30      | 40     |        |        |
| Потребление энергии при выполнении работы $w_i^{FN}$ , ед.энерг./ед.врем. | 120     | 100    |        |        |
| Задания   |         |        |        |        |
| №   | 1       | 2      | 3      | 4      |
| Координаты  | {5, 8}  | {1, 6} | {5, 4} | {2, 7} |

|   | 1     | 2     | 3 | 4     | 5     | 6 | 7 | 8 | 9 | 10 |
|---|-------|-------|---|-------|-------|---|---|---|---|----|
| 1 |       |       |   | $P_1$ |       |   |   |   |   |    |
| 9 |       |       |   |       |       |   |   |   |   |    |
| 8 |       |       |   |       | $Z_1$ |   |   |   |   |    |
| 7 | $P_2$ | $Z_4$ |   |       |       |   |   |   |   |    |
| 6 | $Z_2$ |       |   |       |       |   |   |   |   |    |
| 5 |       |       |   |       |       |   |   |   |   |    |
| 4 |       |       |   |       | $Z_3$ |   |   |   |   |    |
| 3 |       |       |   |       |       |   |   |   |   |    |
| 2 |       |       |   |       |       |   |   |   |   |    |
| 1 |       |       |   |       |       |   |   |   |   |    |

Рис. 3. Расположение роботов и заданий на рабочем поле

При решении задачи порядок заданий для каждого робота определялся таким образом, чтобы все задания были выполнены, а совокупный расход энергии – минимален. Рассматривались различные варианты маршрутов на подмножестве  $R$ , которые охватывают все вершины графа  $G$  и не имеют смежных вершин при минимальной сумме весов ребер. Четыре варианта (из возможных 120) построения маршрутов для рассматриваемого примера расположения двух роботов и четырех задач представлены на рисунке 4.




Рис. 4. Примеры маршрутов-решений на графе  $G$  для задачи с двумя роботами и четырьмя задачами

Полученное решение для рассматриваемого примера сведено в таблице 3, при этом использовались следующие параметры алгоритма:  $t = 50$ ;  $g = 40$ ;  $\alpha = 0,8$ ;  $\beta = 3$ ;  $\rho = 0,3$ .

Таблица 3. Результаты расчета

| № робота | Стратегия | Дистанция маршрута, ед. длин. | Время маршрута, ед. врем. | Число заданий | Суммарные затраты энергии, ед.эн. |
|----------|-----------|-------------------------------|---------------------------|---------------|-----------------------------------|
| 1        | $Z_1-Z_3$ | 6,236                         | 0,208                     | 2             | 420,7                             |
| 2        | $Z_2-Z_4$ | 2,414                         | 0,121                     | 2             |                                   |

Первый робот последовательно выполняет задание 1 ( $Z_1$ ) и задание 3 ( $Z_3$ ), второй робот – задание 2 ( $Z_2$ ) и задание 4 ( $Z_4$ ). Нетрудно убедиться, что найденная стратегия является оптимальной. Рассмотренный подход может быть использован для построения оптимальной стратегии управления произвольной группой мобильных роботов и выполнения произвольного числа заданий [28].

**3.2.1. Генетический алгоритм.** Для решения поставленной задачи с помощью генетических алгоритмов (ГА) необходимо четко сформулировать, что именно является решением этой задачи,

закодировать решение в виде хромосомы и составить функцию приспособленности для таких хромосом. После этого можно решать данную задачу средствами ГА.

Введем разделение роботов на классы. Класс робота будет определять группу заданий, которую он может выполнить, энергопотребление робота в различных режимах и скорость перемещения робота. Выделим три режима (состояния) робота: сон (ожидание задания), перемещение и выполнение задания, каждое из которых характеризуется своим энергопотреблением (для  $i$ -го робота –  $W_i^{SL}$ ,  $W_i^{MV}$ ,  $W_i^{WR}$  соответственно). Каждый робот обладает начальным уровнем заряда ( $P_i^R$ ).

Энергия на функционирование определяется коэффициентом затрат в единицу времени и временем, пока робот активен – с момента получения задания (последовательности заданий) до момента выполнения всех поставленных заданий.

Энергопотребление в результате перемещения определяется количеством энергии, необходимым на преодоление единицы длины.

Энергопотребление на выполнение задания определяется классом робота и классом задания. Задания разделяются на несколько классов. Каждый класс имеет свой уровень энергопотребления ( $W_j^{WR}$ ) – энергия, которую должен затратить робот на выполнение данного класса задания. Робот может выполнить задачу того же, либо более низкого, класса.

С учетом перечисленных характеристик объектов необходимо проработать алгоритм поиска оптимального плана распределения задач между имеющимися роботами с точки зрения минимизации затраченной энергии и времени.

Основная цель выбора показателей качества – минимизация затраченной энергии по группе роботов и времени, затраченного на выполнение плана.

Первым показателем качества является уровень затраченной энергии на выполнение предлагаемого плана распределения задач.

Согласно постановке задачи суммарная энергия, затраченная на выполнение выбранного плана, будет следующей:

$$W_{\Sigma} = \sum_{k \in N_{SL}} W_k^{SL} + \sum_{m \in N_w} (W_m^{MV} + W_m^{WR}), \quad (7)$$



где  $N_{SL}$  – множество роботов, не участвующих в выполнении заданий;  
 $N_w$  – множество роботов, задействованных в выполнении заданий.

Энергозатраты  $i$ -го робота на перемещение  $W_i^{MV}$  из начального положения в пункт выполнения  $j$ -го задания пропорциональны расстоянию от робота до задачи:

$$W_{ij}^{MV} = k_i^{MV} \times S_{ij}, \quad (8)$$

где  $k_i^{MV}$  – расход энергии робота на единицу длины при перемещении, коэффициент пропорционально зависящий от его класса;  
 $S_{ij}$  – расстояние от  $i$ -го робота до  $j$ -го задания, которое будет определяться по нейросетевому алгоритму поиска оптимальной совокупности путей всей группы роботов от исходных точек к задачам.

Вторым показателем качества является время  $t_i$ , необходимое для перемещения  $i$ -го робота из начального положения в пункт выполнения выданного ему задания. Данное время определяется не только скоростью и дистанцией до задания, но и конфигурацией пути робота с учетом объезда препятствий и поочередного прохождения «узких» мест на полигоне совместно с другими роботами, поэтому это время может также определяться в системе планирования траекторий. По совокупности этих времен определяется максимальное время, которое будет устанавливать время выполнения заданий группой роботов:

$$t_{\max} = \max_{m \in N_w} (t_m). \quad (9)$$

Третьим показателем качества является количество невыполненных заданий на данном шаге  $N_{out}$ . Так как число задач и роботов в общем случае может отличаться, необходимо отслеживать, какое количество заданий остается невыполненным.

Таким образом, для рассматриваемой системы в качестве критериев оптимальности использованы:

- 1) общее потребление:

$$j_l(\bar{z}) = W_{\Sigma}(\bar{z}) \rightarrow \min_{z \in Z};$$

- 2) максимальное время выполнения:

$$j_2(\bar{z}) = t_{\max}(\bar{z}) \rightarrow \min_{z \in Z};$$

- 3) число невыполненных заданий:

$$j_3(\bar{z}) = N_{\text{out}}(\bar{z}) \rightarrow \min_{z \in Z}.$$

Здесь  $\bar{z}$  – вектор номеров задач, каждый элемент которого  $z_i$ ,  $i = \overline{1, n}$  определяет задачу для  $i$ -го робота на следующий шаг. Область допустимых значений вектора  $\bar{z}$  образует множество  $Z$ .

Поставим трехкритериальную задачу выбора оптимального плана распределения задач между имеющимися роботами: найти значения варьируемых параметров  $\bar{z}$ , которые в пределе обеспечивают выполнение всех условий 1) – 3). Векторный критерий оптимальности  $(\phi_1(\bar{z}), \phi_2(\bar{z}), \phi_3(\bar{z}))$  определен на множестве  $Z$ , и оператор должен стремиться минимизировать значение каждого из частных критериев оптимальности  $\phi_i(\bar{z})$ ,  $i = \overline{1, n}$ :

$$J: \min_{z \in Z} (\phi_1(\bar{z}), \phi_2(\bar{z}), \phi_3(\bar{z})). \quad (10)$$

Для поиска решения предлагается использовать генетический алгоритм распределения задач в соответствии с перечисленными условиями (ограничениями) и критериями оптимальности.

Следующим шагом является создание фитнесс-функции для выбранной задачи. Укрупненный алгоритм, который был взят за основу при создании функции, следующий:

1. Декодирование хромосомы (производится дешифровка генов в номера задач для каждого робота).
2. Расчет траектории движения роботов к цели.
3. Подсчет параметра  $W_{\Sigma}$  для оцениваемой комбинации заданий согласно выражениям (7)–(9).
4. Подсчет времени, затрачиваемого роботами на выполнение выданной последовательности заданий.

5. Подсчет параметра  $N_{out}$  для оцениваемой комбинации задач как разницы между числом всех заданий  $m$  и количеством ненулевых элементов в векторе  $\bar{z}$ .

6. Вывод полученного вектора значений фитнес–функции для рассматриваемой особи  $\bar{z}$ .

С учетом специфики решаемой задачи для реализации выбранного способа был использован один из эффективных типов алгоритма ГА – алгоритм с проведением сортировки по доминированию, с элитарным отбором (NSGA-II) [29, 30] и целочисленными ограничениями [31]. В случае целочисленного ограничения операция мутации исключается из общего алгоритма (так как не существует функций мутации, которые поддерживают целочисленные ограничения).

Опишем пошагово работу выбранного ГА с учетом выбранных генетических операторов и их параметров при заданном объеме популяции  $R$ :

1. После старта алгоритма создается популяция из  $2 \cdot R$  особей. Начальная популяция генерируется случайным образом с использованием равномерного распределения. Каждая особь – алгоритм команд, состоящий из номеров заданий для каждого робота.

2. Особи оцениваются на уровень приспособляемости по критерию  $Q$ .  $R$  наиболее приспособленных особей включаются в новое поколение.

3. Проводится селекция методом парного турнирного отбора, в результате выбираются группы родителей (особей), которые дадут потомство. Проводится операция скрещивания для отобранных особей (родителей).

4. Создание потомков происходит с использованием однородного кроссовера. В нем скрещивание выполняется на основе бинарного вектора, длина которого равна числу геномов в хромосоме. Каждая позиция вектора определяет взаимную замену генома у родительских особей. Если позиция равна 1 – потомку достанется ген от родителя №1, если позиция равна 0 – от родителя №2. В результате скрещивания создается  $R$  особей-потомков;

5. Шаги повторяются 2–5, если не достигнут критерий выхода из цикла.

Критериями остановки алгоритма служат неизменность лучших особей в течение заданного числа поколений (20–50 поколений зачастую достаточно), либо достижение критического размера числа поколений. Критерий выхода позволяет сократить вероятность попадания в локальный оптимум системы. В то же время

использование NSGA-II и турнира при селекции позволяет ускорить процесс выделения глобального оптимума.

При завершении работы алгоритма среди получившихся  $R$  особей выбираются уникальные (возможно повторение одной из оптимальных особей несколько раз), которые являются оптимальным множеством решений поставленной проблемы (рисунок 5).

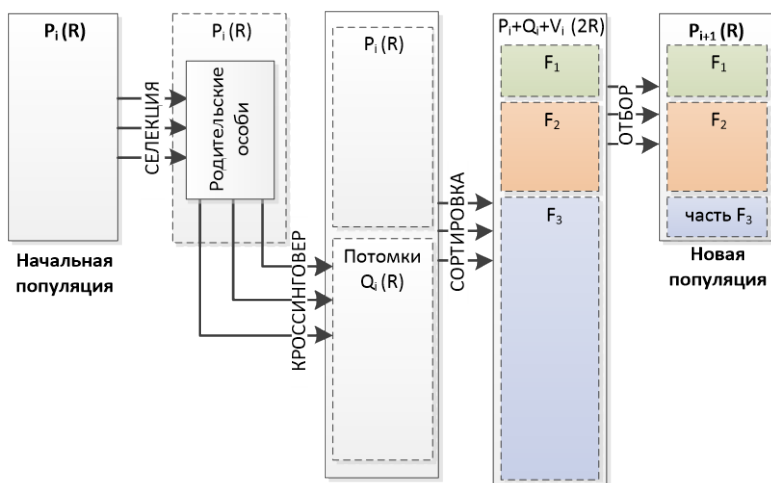


Рис. 5. Структура NSGA-II

**3.2.2. Численные эксперименты.** Рассмотрим группу из трех роботов, которым могут быть назначены шесть заданий. Рабочее пространство представляется в виде дискретного поля размером  $10 \times 10$  клеток. Исходные данные для рассматриваемого примера приведены в таблицах 4–6. Расположение роботов и заданий на поле представлено на рисунке 6.

Таблица 4. Параметры роботов и задач на поле

| Робот, № | Координаты | Класс | $P_1^R$<br>ед.эн. | Задания<br>№ | Координаты | Класс |
|----------|------------|-------|-------------------|--------------|------------|-------|
| 1        | {6,2}      | 3     | 40                | 1            | {8,3}      | 1     |
| 2        | {4,10}     | 1     | 40                | 2            | {1,6}      | 1     |
| 3        | {1,7}      | 2     | 40                | 3            | {5,4}      | 2     |
|          |            |       |                   | 4            | {4,9}      | 3     |
|          |            |       |                   | 5            | {2,10}     | 3     |
|          |            |       |                   | 6            | {2,7}      | 1     |

Таблица 5. Энергетические параметры

| Класс<br>робота | $W^{SL}$ ,<br>ед.эн. | $k^{MV}$ ,<br>ед.эн./ед.дл. | $M_v$ , ед.дл./<br>ед.вр. | Класс<br>заданий | $W^{WR}$ ,<br>ед.эн. |
|-----------------|----------------------|-----------------------------|---------------------------|------------------|----------------------|
| 1               | 2,1                  | 0,7                         | 100                       | 1                | 3,2                  |
| 2               | 1,1                  | 1,2                         | 200                       | 2                | 2,8                  |
| 3               | 1,7                  | 0,9                         | 150                       | 3                | 5,8                  |

Таблица 6. Время обработки заданий

| Класс робота | Класс заданий |   |   |
|--------------|---------------|---|---|
|              | 1             | 2 | 3 |
| 1            | 3             | - | - |
| 2            | 5             | 4 | - |
| 3            | 5             | 7 | 2 |

|   | 1           | 2           | 3 | 4           | 5           | 6           | 7 | 8           | 9 | 10 |
|---|-------------|-------------|---|-------------|-------------|-------------|---|-------------|---|----|
| 1 |             | $z_5^{(3)}$ |   | $P_2^{(1)}$ |             |             |   |             |   |    |
| 9 |             |             |   | $z_4^{(3)}$ |             |             |   |             |   |    |
| 8 |             |             |   |             |             |             |   |             |   |    |
| 7 | $P_3^{(2)}$ | $z_6^{(1)}$ |   |             |             |             |   |             |   |    |
| 6 | $z_2^{(1)}$ |             |   |             |             |             |   |             |   |    |
| 5 |             |             |   |             |             |             |   |             |   |    |
| 4 |             |             |   |             | $z_3^{(2)}$ |             |   |             |   |    |
| 3 |             |             |   |             |             |             |   | $z_1^{(1)}$ |   |    |
| 2 |             |             |   |             |             | $P_1^{(3)}$ |   |             |   |    |
| 1 |             |             |   |             |             |             |   |             |   |    |

Рис. 6. Расположение роботов и задач на рабочем поле

Расчет проводится с глубиной анализа в 4 задания. Другими словами, для каждого робота генерируется последовательная цепь из 4 заданий.

Полные результаты решения трехкритериальной оптимизационной задачи представлены в таблице 7.

Таблица 7. Оптимальные решения

| № решения | $W_{\Sigma}$ , ед.эн. | $t_{\max}$ , ед.вр. | $N_{\text{out}}$ |
|-----------|-----------------------|---------------------|------------------|
| 1.1       | 125,18                | 59,94               | 0                |
| 1.2       | 117,66                | 60,40               | 0                |
| 1.3       | 112,83                | 49,01               | 1                |
| 1.4       | 105,39                | 51,53               | 1                |
| 1.5       | 89,09                 | 54,14               | 1                |
| 1.6       | 89,29                 | 33,84               | 2                |
| 1.7       | 82,35                 | 35,51               | 2                |
| 1.8       | 81,13                 | 36,90               | 2                |
| 1.9       | 80,77                 | 41,64               | 2                |
| 1.10      | 49,00                 | 22,93               | 3                |
| 1.11      | 65,19                 | 19,93               | 4                |
| 1.12      | 55,66                 | 15,93               | 5                |

Рассмотрим более подробно полученные решения для  $N_{\text{out}} = 0$ . Цепи заданий для каждого из роботов представлены в таблице 8.

Таблица 8. Оптимальные решения

| №   | Стратегия (цепи заданий)       |                                |  | $W_{\Sigma}$ , ед.эн. | $t_{\max}$ , ед.вр. | $N_{\text{out}}$ |
|-----|--------------------------------|--------------------------------|--|-----------------------|---------------------|------------------|
|     | 1                              | 2                              | 3  |                       |                     |                  |
| 1.1 | 3 <sub>4</sub> -3 <sub>5</sub> | 3 <sub>1</sub>                 | 3 <sub>2</sub> -3 <sub>3</sub> -3 <sub>6</sub> | 125,18                | 59,94               | 0                |
| 1.2 | 3 <sub>4</sub> -3 <sub>5</sub> | 3 <sub>2</sub> -3 <sub>6</sub> | 3 <sub>1</sub> -3 <sub>3</sub>                 | 117,66                | 60,40               | 0                |

Таким образом, получено 12 уникальных стратегий поведения роботов, из которых два близки к оптимальным решениям - с нулевым количеством невыполненных заданий. В зависимости от требуемых условий поиска полученные решения позволяют:

1. оценить максимально возможное число выполненных операций данной группой роботов из условия ограниченного резерва по энергии или по времени;
2. выбрать наиболее быструю, либо наиболее энергосберегающую стратегию исходя из требуемого числа выполненных задач.

В работе [32] более подробно показано использование ГА для распределения задач и решения многокритериальной оптимизационной задачи с учетом временных затрат и интегрального критерия эффективности роботов, учитывающего энергетические затраты, функциональную насыщенность каждого агента группы и т.д.

**3.3.1. Нейросетевой алгоритм Хопфилда.** В 1985 г. Хопфилд и Танк [33] показали, что нейронная сеть с обратной связью может быть использована для решения задач комбинаторной оптимизации, таких как TSP. В настоящее время модель Хопфилда успешно применяется во многих областях, ключевым вопросом при ее применении является выбор весов в функции энергии, позволяющих получить быструю сходимость и подавить ложные состояния.

В процессе работы динамика таких сетей сходится к одному из положений равновесия, которые являются локальными минимумами функционала энергии сети [34].

Функционал энергии сети является функцией оптимизации, которая в общем виде содержит 4 компонента:

$$\begin{aligned}
 E(g) &= E_1 + E_2 + E_3 + E_4; \\
 \left\{ \begin{aligned}
 E_1 &= A \sum_X \sum_i \sum_{j \neq i} g_{X_i} g_{Y_j}; \\
 E_2 &= B \sum_i \sum_X \sum_{X'Y} g_{X_i} g_{Y_i}; \\
 E_3 &= C \left( \sum_X \sum_i g_{X_i} - N \right)^2; \\
 E_4 &= D \sum_X \sum_{Y \neq X} \sum_i d_{XY} g_{X_i} (g_{Y_i} + g_{Y_{i-1}});
 \end{aligned} \right. \quad (11)
 \end{aligned}$$

где  $g_{X_i}$  – логический параметр узла  $X_i$  графа (может принимать значение 0 или 1);  $d_{XY}$  – вес ненаправленного ребра между узлами  $X$  и  $Y$ ;  $A, B, C, D$  – относительные веса слагаемых.

Первые три слагаемых –  $E_1, E_2, E_3$  – отвечают за допустимость маршрута: каждый город должен быть посещен не более чем один раз (в каждой строке матрицы имеется не более одной единицы), под каждым номером должно посещаться не более одного города (в каждом столбце – не более одной единицы) и, кроме того, общее число посещений равно числу городов  $N$  (в матрице всего имеется ровно  $N$  единиц).

Четвертое слагаемое  $E_4$  – коэффициент, пропорциональный энергии (суммарному весу выбранного маршрута) нейросети.

Метка  $g_{X_i}$  определяется потенциалом узла  $u_{X_i}$  следующим выражением:

$$g_{xi} = \frac{1 + \tanh(u_{xi}/u_0)}{2}. \quad (12)$$

Начальное значение потенциала:

$$u_{in} = \frac{u_0}{2} \ln(n-1), \quad (13)$$

где  $u_0$  – пороговый уровень потенциала.

Входной потенциал имеет следующее значение:

$$u_{xi} = -\frac{\partial E}{\partial u_{xi}}. \quad (14)$$

С учетом данных выражений модель нейродинамики сети Хопфилда задается в виде:

$$\frac{du_{xi}}{dt} = -\frac{u_{xi}}{\tau} - \left[ \begin{array}{l} A \sum_{ji} g_{xi} + B \sum_{xy} g_{yi} + C \left( \sum_x \sum_i g_{xi} - N \right) + \\ + D \sum_Y d_{xy} (g_{yi+1} + g_{yi-1}) \end{array} \right], \quad (15)$$

где  $\tau$  – числовой параметр.

Пересчитанные в (14) и (15) значения потенциала можно использовать при перерасчете меток  $g_{xi}$  согласно выражению (12). Процесс повторяется некоторое число раз. Если рассчитанные метки обнуляют уравнения (11), выбранный вариант матрицы принимается оптимальным.

В итоговой маршрутной матрице (состоит из оценок меток  $g_{xi}$ ) номер столбца отвечает номеру шага обхода, а номер строки в столбце – номеру узла, к которому необходимо перейти.

**3.3.2. Численные эксперименты.** В качестве работы алгоритма приведем результаты моделирования для ранее рассмотренного примера для двух роботов и четырех задач (рисунок 3) с исходными данными из таблицы 1.

Для перехода к графу необходимо и достаточно представить всю группу роботов и заданий на поле в виде вершин графа. Зададим смешанный граф  $G = \{V, A\}$ , где  $A$  – множество неориентированных



ребер;  $V = \{R \cup W\}$  – объединение непересекающихся множеств вершин  $R$ , соответствующих роботам, и вершин  $W$ , соответствующих заданиям.

В графе  $G$  подграф  $W$  является полным. Любая пара вершин из подмножества  $R$  не является соседней. Каждое ребро является взвешенным. Граф, построенный для заданного положения роботов и задач, будет аналогичен графу, показанному на рисунке 1.

С помощью формулы (1) задаются веса соответствующих ребер в системе. Результатом работы нейросети является гамильтонов цикл, который показан на рисунке 7 слева, а справа приведен результат обратного преобразования результата решения задачи TSP в стратегию поведения роботов.

Использование нейросети Хопфилда позволяет корректно решить задачу оптимизации маршрута при управлении малыми группами роботов (число вершин равно  $N=6$ ). Для задач большей размерности (к примеру, для  $N=20$ ) результат решения и время расчета будет определяться выбором свободных параметров сети.

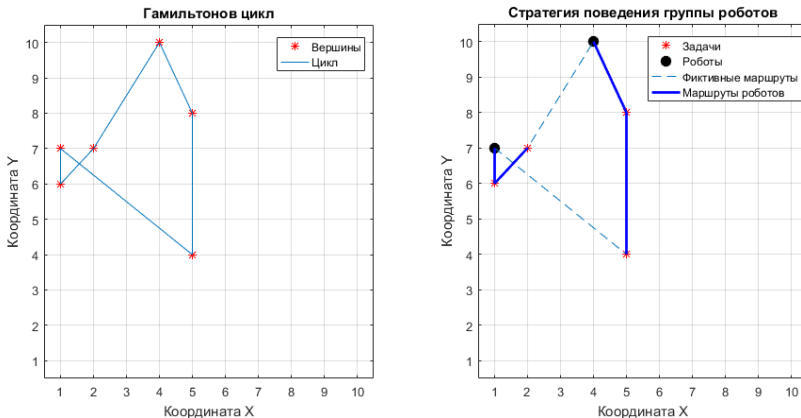


Рис. 7. Результат расчета стратегии поведения группы роботов с использованием нейросети Хопфилда

Таким образом, для возможности использования нейронной сети исходная задача была сведена к задаче коммивояжера, уже в решении которой был использован классический алгоритм нейронной сети Хопфилда.

Отличительной особенностью данного типа рекуррентной нейросети является отсутствие необходимости обучения при решении

оптимизационных задач, что позволяет использовать данную нейросеть для решения рассматриваемой задачи.

Поиск стационарного состояния нейросети позволил получить оптимальную стратегию поведения роботов для задачи низкой размерности (6 вершин) при минимизации суммарной длины пути следования. Более подробное описание метода приводится в работе [35].

**4. Оценка эффективности алгоритмов.** После анализа каждого из алгоритмов приведем сравнение их характеристик (таблица 9).

В качестве основных характеристик рассмотрим:

- точность решения (насколько эффективен алгоритм при поиске глобального оптимума);
- метод оптимизации (какой метод лежит в основе алгоритма);
- сложность (вычислительная сложность алгоритма в зависимости от размерности задачи).

Таблица 9. Сравнение характеристик рассмотренных алгоритмов

| Характеристика    | Алгоритм  |   |   |
|-------------------|---|---|---|
|                   | Муравьиный  | Генетический  | Нейронная сеть Хопфилда   |
| Точность решения  | близкая к границе Парето                                    | близкая к границе Парето, свойственна остановка на локальном оптимуме | близкая к границе Парето, свойственно появление случайных неоптимальных решений |
| Метод оптимизации | метаэвристическая оптимизация по примеру поведения муравьев | наследование, мутация, отбор и кроссинговер                           | минимизация энергетической функции Ляпунова                                     |
| Сложность         | $O(n^3)$  | $O(n^2)$  |   |

Следует отметить, что для каждого алгоритма решение может быть улучшено за счет использования метаоптимизации. При этом временная сложность алгоритма увеличится (зависит от используемых методов метаоптимизации), однако решение приблизится к глобальному оптимуму за счет исключения локальных дефектов.

Количественное сравнение эффективности алгоритмов при решении исходной задачи может быть проведено только после реализации каждого из алгоритмов и анализа решений группы типовых задач распределения заданий для группы автономных роботов.

**5. Заключение.** В работе проведен анализ исходной задачи распределения заданий для группы автономных роботов. Определено, что данная задача является NP-сложной и ее решение прямым перебором для большого числа заданий (более 66) невозможно. Проведено сведение исходной задачи к типовым NP-полным задачам: обобщенной задаче поиска оптимальной группы замкнутых маршрутов от одного депо (VRP) и задаче коммивояжера (TSP).

Проведен обзор эвристических методов поиска квазиоптимального решения NP-полных задач. Выделено три алгоритма, которые наиболее часто используются для решения данного типа задач: муравьиный, генетический и нейросетевой.

В приведенных в статье алгоритмах не учитывался один из наиболее используемых критериев – величина запаса энергии на борту робота, – так как рассматривался вариант построения группы с возможностью обмена энергией между агентами.

Проведено описание каждого из выбранных алгоритмов, показана специфика их применения и выполнено сравнение ключевых характеристик. В дальнейшем планируется провести более подробный сравнительный анализ применимости данных алгоритмов для решения задачи оптимизации распределения заданий для групп с большим числом роботов как для гомогенных, так и для гетерогенных составов.

### Литература

1. Kalyaev I. et al. A novel method for distribution of goals among UAVs for oil field monitoring // IEEE 6th ICIEVISMHT, Himeji, Japan. 2017. pp. 1–4.
2. ONDRACEK J. Intelligent Algorithms for Monitoring of the Environment Around Oil Pipe Systems Using Unmanned Aerial Systems. – Bachelor's thesis. Czech Technical University in Prague, 2014.
3. CASBEER D.W. et al. Forest fire monitoring with multiple small UAVs // Proc. of the American Control Conference, June 2005, Portland, Oregon. 2005. pp. 3530–3535.
4. SUJIT P.B., KINGSTON D., BEARD R. Cooperative forest fire monitoring using multiple UAVs // 46th IEEE Conference on Decision and Control, 10–11 December 2007, New Orleans, Louisiana USA. 2007. pp. 4875–4880.
5. Khamis A., Hussein A., Elmogy A. Multi-robot Task Allocation: A Review of the State-of-the-Art. In: Koubâa A., Martínez-de Dios J. (eds) Cooperative Robots and Sensor Networks 2015. Studies in Computational Intelligence, vol 604. Springer, Cham.
6. Yi-Lin, L., Kuo-Lan, S. Multi-robot-based intelligent security system. *Artif. Life Robot.* 16, 137–141 (2011).

7. Marino, A., Parker, L.E., Antonelli, G., Caccavale, F. A decentralized architecture for multi-robot systems based on the null-space-behavioral control with application to multi-robot border patrolling. *J. Intell. Robot. Syst.* 71, pp. 423–444.
8. Иванов Д.Я. Распределение ролей в коалициях роботов при ограниченных коммуникациях на основе роевого взаимодействия // *Управление большими системами*. Институт проблем управления им. В.А. Трапезникова РАН, 2019. Vol. 78. С. 23–45.
9. Jian-Ping Wang, Yuesheng Gu and Xiao-Min Li Multi-robot Task Allocation Based on Ant Colony Algorithm // *Journal of Computers* vol. 7, no. 9, pp. 2160-2167, 2012.
10. Кубил В.Н. Обзор обобщений и расширений задачи маршрутизации транспорта // *Вестник РГУПС*, № 2, 2018. С. 97-109.
11. Chao I.M., Golden B.L., Wasil E. A new heuristic for the multi-depot vehicle routing problem that improves upon best-known solutions // *American Journal of Mathematical and Management Sciences*, Vol. 13, No. 3-4, 1993. pp. 371-406.
12. Choi E., Tcha D.W. A column generation approach to the heterogeneous fleet vehicle routing problem // *Computers & Operations Research*, Vol. 34, No. 7, 2007. pp. 2080-2095.
13. Кубил В.Н. Пространство решений задач коммивояжера и маршрутизации транспорта // *Фундаментальные исследования, методы и алгоритмы прикладной математики в технике, медицине и экономике: материалы 16-ой Междунар. молодежн. науч.-практ. конф. ЮРГПУ (НПИ)*. Новочеркасск : Лик. 2017. С. 33-39.
14. Bremermann H.J. Optimization through evolution and recombination // *Yovits M.C., Jacobi G.T. and Goldstein G.D. (Eds.), Self-Organizing Systems*, 1962. pp. 93-106.
15. Зайцев А.А. Обзор эволюционных методов оптимизации на основе роевого интеллекта / А.А. Зайцев, В.В. Курейчик, А.А. Полуланов // *Известия ЮФУ*. 2010. № 12 (113). С. 7–12.
16. Engelbrecht A.P. *Fundamentals of Computational Swarm Intelligence*. John Wiley & Sons, Chichester, UK, 2005.
17. Литовка Н.В. Роевой интеллект в задачах оптимального размещения объектов пространственно распределенного предприятия/ Н.В. Литовка// *Научные труды КубГТУ*, № 11, 2018 год.
18. Dorigo M. *Swarm Intelligence, Ant Algorithms and Ant Colony Optimization* // Reader for CEU Summer University Course «Complex System». Budapest, Central European University, 2001. pp. 1–38.
19. Caro G.D., Dorigo M. *Anet a Mobile Agents Approach to Adaptive Routing*. Technical Report IRIDA 97-12. IRIDA. Universite Libre de Bruxelles. Brussels, Belgium, 1997. 27 p.
20. Курейчик В.В., Запорожец Д.Ю. Роевой алгоритм в задачах оптимизации // *Известия ЮФУ. Технические науки*. 2010. №7. С. 28-32.
21. Liping Zhu Remarkable problem-solving ability of unicellular amoeboid organism and its mechanism// *Liping Zhu, Song-Ju Kim, Masahiko Hara and Masashi Aono*, 2018 (<https://royalsocietypublishing.org/doi/10.1098/rsos.180396>).
22. Ежов А.А. Дообучение нейронной сети Хопфилда: поиск глобального минимума функционала и модель быстрого сна// *Ежов А.А., Черепнев А.С./ Математическое моделирование*. 2009. Т. 21. № 5. С. 10-20.
23. Лоскутов А.И. Решение задачи о ранце на основе динамической нейронной сети Хопфилда// *Лоскутов А.И., Горбулин В.И., Карпушев С.И., Ряхова Е.А./ Нелинейный мир*. 2019. Т. 17. № 3. С. 25-35.
24. Хайкин С. *Нейронные сети*. Полный курс. Изд. 2-е, испр. М.: Вильямс. 2016. 1104 с.
25. Музычин В.В. Исследование возможности использования рекуррентной нейронной сети Хопфилда для решения задачи коммивояжера// *Музычин В.В.*,

- Мацевский С.В./ Современная наука: актуальные проблемы теории и практики. Серия: Естественные и технические науки. 2020. № 5. С. 93-99.
26. Кубил В.Н. Исследование и разработка методов решения многокритериальных задач маршрутизации транспорта на основе муравьиного алгоритма: дис.. канд. т. наук. Южно-Российский гос. политехнический университет имени М.И. Платова, Новочеркасск, 2019.
  27. Кубил В.Н., Мохов В.А. Многоколонийный муравьиный алгоритм с модификациями для решения многокритериальных задач маршрутизации транспорта // Известия высших учебных заведений. Электромеханика, Т. 61, № 6, 2018. С. 94-109.
  28. Migranov A.B., Darintsev O.V. Choosing a Swarm Algorithm to Synthesis an Optimal Mobile Robot Team Control Strategy // 2020 International Multi-Conference on Industrial Engineering and Modern Technologies, Vladivostok, Russia, 2020, pp. 1-5.
  29. Лотов А.В. Многокритериальные задачи принятия решений: Учебное пособие/ А.В. Лотов, И.И. Поспелова. – М.: МАКС Пресс, 2008. – 197 с.
  30. Goldberg D. Genetic Algorithms in Search, Optimization, and Machine Learning/ D. Goldberg. – Massachusetts: Addison-Wesley, 1989.
  31. Панченко Т.В. Генетические алгоритмы: учебно-методическое пособие/ Т.В. Панченко; под ред. Ю.Ю. Тарасевича. – Астрахань: Издательский дом «Астраханский университет», 2007. – 87 с.
  32. Migranov A.B., Darintsev O.V. The Use of Genetic Algorithms for Distribution of Tasks in Groups of Mobile Robots with Minimization of Energy Consumption // 2019 International Multi-Conference on Industrial Engineering and Modern Technologies, Vladivostok, Russia, 2019, pp. 1-6.
  33. Hopfield, J.J., Tank, D.W. (1985). Neural Computation of Decisions in Optimization Problems. Biological Cybernetics, Vol. 52, pp.141-152.
  34. Кононов А.А. Использование метода нейронных сетей Хопфилда для решения задачи маршрутизации в сети// Кононов А.А./ Московский экономический журнал, №9, 2019. С.74
  35. Darintsev O.V. Migranov A.B. Using the Hopfield Neural Network to Select a Behaviour Strategy for the Group of Mobile Robots // IOP Publishing, 2021, J. Phys.: Conf. Ser. 2096 012086

**Даринцев Олег Владимирович** — д-р техн. наук, доцент, главный научный сотрудник, лаборатория «робототехника и управление в технических системах», Институт механики им. Р.Р. Мавлютова — обособленное структурное подразделение Уфимского федерального исследовательского центра Российской академии наук; профессор, кафедра автоматизации технологических процессов, Уфимский государственный авиационный технический университет. Область научных интересов: робототехника, микроробототехника, МЭМС, искусственный интеллект, системы обработки информации, СТЗ. Число научных публикаций — 230. ovd@uimech.org; Проспект Октября, 71, 450054, Уфа, Россия; р.т.: +7(347)225-5255.

**Мигранов Айрат Барисович** — канд. техн. наук, старший научный сотрудник, лаборатория «робототехника и управление в технических системах», Институт механики им. Р.Р. Мавлютова — обособленное структурное подразделение Уфимского федерального исследовательского центра Российской академии наук. Область научных интересов: микроробототехника, МЭМС, искусственный интеллект. Число научных публикаций — 138. abm.imech.anrb@mail.ru; Проспект Октября, 71, 450054, Уфа, Россия; р.т.: +7(347)225-5255.

**Поддержка исследований.** Работа выполнена в рамках госзадания FWGZ-2019-0089.

O. DARINTSEV, A. MIGRANOV

## ANALYTICAL REVIEW OF APPROACHES TO THE DISTRIBUTION OF TASKS FOR MOBILE ROBOT TEAMS BASED ON SOFT COMPUTING TECHNOLOGIES

*Darintsev O., Migranov A. Analytical Review of Approaches to the Distribution of Tasks for Mobile Robot teams Based on Soft Computing Technologies.*

**Abstract.** The use of various types of heuristic algorithms based on soft computing technologies for the distribution of tasks in groups of mobile robots performing monosyllabic operations in a single workspace is considered: genetic algorithms, ant algorithms and artificial neural networks. It is shown that this problem is NP-complex and its solution by direct iteration for a large number of tasks is impossible. The initial problem is reduced to typical NP-complete problems: the generalized problem of finding the optimal group of closed routes from one depot and the traveling salesman problem. A description of each of the selected algorithms and a comparison of their characteristics are presented. A step-by-step algorithm of operation is given, taking into account the selected genetic operators and their parameters for a given population volume. The general structure of the developed algorithm is presented, which makes it possible to solve a multi-criteria optimization problem efficiently enough, taking into account time costs and the integral criterion of robot efficiency, taking into account energy costs, functional saturation of each agent of the group, etc. The possibility of solving the initial problem using an ant algorithm and a generalized search for the optimal group of closed routes is shown. For multi-criteria optimization, the possibility of linear convolution of the obtained vector optimality criterion is shown by introducing additional parameters characterizing group control: the overall efficiency of the functioning of all robots, the energy costs for the functioning of the support group and the energy for placing one robot on the work field. To solve the task distribution problem using the Hopfield neural network, its representation is made in the form of a graph obtained during the transition from the generalized task of finding the optimal group of closed routes from one depot to the traveling salesman problem. The quality indicator is the total path traveled by each of the robots in the group.

**Keywords:** team of robots, distribution of tasks, genetic algorithm, ant algorithm, Hopfield neural network.

### References

1. Kalyaev I. et al. A novel method for distribution of goals among UAVs for oil field monitoring // IEEE 6th ICIEVISMHT, Himeji, Japan. 2017. pp. 1–4.
2. ONDRACEK J. Intelligent Algorithms for Monitoring of the Environment Around Oil Pipe Systems Using Unmanned Aerial Systems. – Bachelor's thesis. Czech Technical University in Prague, 2014.
3. CASBEER D.W. et al. Forest fire monitoring with multiple small UAVs // Proc. of the American Control Conference, June 2005, Portland, Oregon. 2005. pp. 3530–3535.
4. SUJIT P.B., KINGSTON D., BEARD R. Cooperative forest fire monitoring using multiple UAVs // 46th IEEE Conference on Decision and Control, 10-11 December 2007, New Orleans, Louisiana USA. 2007. pp. 4875–4880.
5. Khamis A., Hussein A., Elmogy A. Multi-robot Task Allocation: A Review of the State-of-the-Art. In: Koubãa A., Martínez-de Dios J. (eds) Cooperative Robots and Sensor Networks 2015. Studies in Computational Intelligence, vol. 604. Springer, Cham.

6. Yi-Lin, L., Kuo-Lan, S. Multi-robot-based intelligent security system. *Artif. Life Robot.* 16, 2011. pp. 137–141.
7. Marino, A., Parker, L.E., Antonelli, G., Caccavale, F. A decentralized architecture for multi-robot systems based on the null-space-behavioral control with application to multi-robot border patrolling. *J. Intell. Robot. Syst.* 71, pp. 423–444.
8. Ivanov D.Ja. Raspredeleenie rolev v koalitsijah robotov pri ogranichennoj kommunikacii na osnove roevogo vzaimodejstvija // *Upravlenie bol'shimi sistemami. Institut problem upravlenija im. VA Trapeznikova RAN*, 2019. Vol. 78. pp. 23–45. (In Russ.).
9. Jian-Ping Wang, Yueheng Gu and Xiao-Min Li Multi-robot Task Allocation Based on Ant Colony Algorithm // *Journal of Computers* vol. 7, no. 9, 2012. pp. 2160-2167.
10. Kubil V.N. Obzor obobshhenij i rasshirenij zadachi marshrutizacii transporta // *Vestnik RGUPS*, № 2, 2018. pp. 97-109. (In Russ.).
11. Chao I.M., Golden B.L., Wasil E. A new heuristic for the multi-depot vehicle routing problem that improves upon best-known solutions // *American Journal of Mathematical and Management Sciences*, Vol. 13, No. 3-4, 1993. pp. 371-406.
12. Choi E., Tcha D.W. A column generation approach to the heterogeneous fleet vehicle routing problem // *Computers & Operations Research*, Vol. 34, No. 7, 2007. pp. 2080-2095.
13. Kubil V.N. Prostranstvo reshenij zadach kommivozazhera i marshrutizacii transporta // *Fundamentalnye issledovanija, metody i algoritmy prikladnoj matematiki v tehnike, medicine i jekonomike : materialy 16-oj Mezhdunar. molodezhn. nauch.-prakt. konf. JuRGPU (NPI). Novocherkassk : Lik.* 2017. pp. 33-39. (In Russ.).
14. Bremermann H.J. Optimization through evolution and recombination // *Yovits M.C., Jacobi G.T. and Goldstein G.D. (Eds.), Self-Organizing Systems*, 1962. pp. 93-106.
15. Zajcev A.A. Obzor jevoljucionnyh metodov optimizacii na osnove roevogo intelekta / A. A. Zajcev, V. V. Kurejchik, A. A. Polupanov // *Izvestija JuFU*. 2010. № 12 (113). pp. 7–12. (In Russ.).
16. Engelbrecht A.P. *Fundamentals of Computational Swarm Intelligence*. John Wiley & Sons, Chichester, UK, 2005.
17. Litovka N.V. Roevoj intellekt v zadachah optimal'nogo razmeshhenija ob'ektov prostranstvenno raspredeleennogo predprijatija/ N.V. Litovka// *Nauchnye trudy KubGTU*, № 11, 2018. (In Russ.).
18. Dorigo M. *Swarm Intelligence, Ant Algorithms and Ant Colony Optimization // Reader for CEU Summer University Course «Complex System»*. Budapest, Central European University, 2001. pp. 1–38.
19. Caro G.D., Dorigo M. *Anet a Mobile Agents Approach to Adaptive Routing*. Technical Report IRIDA 97-12. IRIDA. Universite Libre de Bruxelles. Brussels, Belgium, 1997. 27 p.
20. Kurejchik V.V., Zaporozhec D.Ju. Roevoj algoritm v zadachah optimizacii // *Izvestija JuFU. Tehnicheskie nauki*. 2010. №7. pp. 28-32. (In Russ.).
21. Liping Zhu Remarkable problem-solving ability of unicellular amoeboid organism and its mechanism// Liping Zhu, Song-Ju Kim, Masahiko Hara and Masashi Aono, 2018 (<https://royalsocietypublishing.org/doi/10.1098/rsos.180396>).
22. Ezhov A.A. Doobuchenie nejronnoj seti Hopfilda: poisk global'nogo minimuma funkcionala i model' bystrogo sna// Ezhov A.A., Cherepnev A.S./ *Matematicheskoe modelirovanie*. 2009. T. 21. № 5. pp. 10-20. (In Russ.).
23. Loskutov A.I. Reshenie zadachi o rance na osnove dinamicheskoj nejronnoj seti Hopfilda// Loskutov A.I., Gorbulin V.I., Karpushev S.I., Rjahova E.A./ *Nelinejnij mir*. 2019. T. 17. № 3. pp. 25-35. (In Russ.).
24. Hajkin S. *Nejronnye seti. Polnyj kurs*. Izd. 2-e, ispr. M.: Vil'jams. 2016. 1104 p. (In Russ.).
25. Muzychin V.V. Issledovanie vozmozhnosti ispol'zovanija rekurrentnoj nejronnoj seti Hopfilda dlja reshenija zadachi kommivozazhera// Muzychin V.V., Macievskij S.V./

- Sovremennaja nauka: aktual'nye problemy teorii i praktiki. Serija: Estestvennye i tehničeskie nauki. 2020. № 5. pp. 93-99. (In Russ.).
26. Kubil V.N. Issledovanie i razrabotka metodov reshenija mnogokriterial'nyh zadach marshrutizacii transporta na osnove murav'inogo algoritma: dis.. kand. t. nauk. Juzhno-Rossijskij gos. politehničeskij universitet imeni M.I. Platova, Novočerkassk, 2019. (In Russ.).
  27. Kubil V.N., Mohov V.A. Mnogokolonial'nyj murav'inij algoritm s modifikacijami dlja reshenija mnogokriterial'nyh zadach marshrutizacii transporta // Izvestija vysshih učebynyh zavedenij. Jelektromehanika, T. 61, № 6, 2018. pp. 94-109. (In Russ.).
  28. Migranov A.B., Darintsev O.V. Choosing a Swarm Algorithm to Synthesis an Optimal Mobile Robot Team Control Strategy // 2020 International Multi-Conference on Industrial Engineering and Modern Technologies, Vladivostok, Russia, 2020, pp. 1-5. Deb, Kalyanmoy Multi-Objective Optimization Using Evolutionary Algorithms. John Wiley & Sons, 2001.
  29. Lotov A.V. Mnogokriterial'nye zadachi prinyatiya reshenij: Učebnoe posobie/ A.V. Lotov, I.I. Pospelova. MAKS Press, 2008. 197 p. (In Russ.).
  30. Goldberg D. Genetic Algorithms in Search, Optimization, and Machine Learning/ D. Goldberg. – Massachusetts: Addison-Wesley, 1989. Kononov A.A. Ispol'zovanie metoda nejronnyh setej Hopfilda dlja reshenija zadachi marshrutizacii v seti// Kononov A.A/ Moskovskij jekonomičeskij žurnal, №9, 2019. p.74(In Russ.).
  31. Panchenko T.V. Genetičeskie algoritmy: učebno-metodičeskoe posobie/ T.V. Panchenko; pod red. YU.YU. Taraseviča. Astrahan': Izdatel'skij dom "Astrahanskij universitet", 2007. 87 p. (In Russ.).
  32. Migranov A.B., Darintsev O.V. The Use of Genetic Algorithms for Distribution of Tasks in Groups of Mobile Robots with Minimization of Energy Consumption // 2019 International Multi-Conference on Industrial Engineering and Modern Technologies, Vladivostok, Russia, 2019, pp. 1-6.
  33. Hopfield, J.J., Tank, D.W. (1985). Neural Computation of Decisions in Optimization Problems. Biological Cybernetics, Vol. 52, pp.141-152.
  34. Kononov A.A. Ispol'zovanie metoda nejronnyh setej Hopfilda dlja reshenija zadachi marshrutizacii v seti// Kononov A.A/ Moskovskij jekonomičeskij žurnal, №9, 2019. p.74(In Russ.).
  35. Darintsev O.V. Migranov A.B. Using the Hopfield Neural Network to Select a Behaviour Strategy for the Group of Mobile Robots // IOP Publishing, 2021, J. Phys.: Conf. Ser. 2096 012086

**Darintsev Oleg** — Ph.D., Dr.Sci., Associate Professor, Chief researcher, Laboratory "robotics and control in technical systems", Mavlyutov Institute of Mechanics - Subdivision of the Ufa Federal Research Center of the Russian Academy of Sciences; Professor, Department of automation of technological processes, Ufa State Aviation Technical University. Research interests: robotics, microrobotics, MEMS, artificial intelligence, information processing systems, technical vision system. The number of publications — 230. ovd@uimech.org; 71, Prospekt Oktyabrya, 450054, Ufa, Russia; office phone: +7(347)225-5255.

**Migranov Ayrat** — Ph.D., Senior researcher, Laboratory "robotics and control in technical systems", Mavlyutov Institute of Mechanics - Subdivision of the Ufa Federal Research Center of the Russian Academy of Sciences. Research interests: robotics, microrobotics, artificial intelligence. The number of publications — 138. abm.imech.anrb@mail.ru; 71, Prospekt Oktyabrya, 450054, Ufa, Russia; office phone: +7(347)225-5255.

**Acknowledgements.** This research is supported by the framework of the state task (FWGZ-2019-0089).



М.В. ИВАНОВ, А.А. ПОЛУНИН  
**ПОВЫШЕНИЕ ТОЧНОСТИ IP-ГЕОЛОКАЦИИ НА ОСНОВЕ  
ДАННЫХ, ПРЕДОСТАВЛЯЕМЫХ ОТКРЫТЫМИ  
IP-ГЕОСЕРВИСАМИ**

*Иванов М.В., Полунин А.А. Повышение точности IP-геолокации на основе данных, предоставляемых открытыми IP-геосервисами.*

**Аннотация.** IP-геолокация – это процесс определения реального географического положения электронного устройства, подключенного к сети Интернет, по его глобальному сетевому адресу [1]. В настоящее время она нашла широкое применение в интернет-торговле, маркетинге и рекламе, информационной безопасности [2] и других направлениях человеческой деятельности. Применяются различные подходы к определению местоположения удаленного сетевого устройства, различающиеся как по типу анализируемой информации (задержка передачи пакетов, ресурсные записи DNS-серверов, контент веб-страниц), так и по выдаваемому результату (название страны или города, почтовый адрес, вероятная зона расположения или точные координаты) [3, 4]. Ошибка IP-геолокации зависит от страны расположения устройства, плотности населения, типа сетевого устройства и лежит в пределах от нескольких десятков метров до сотен километров. При этом для одних и тех же входных данных результаты разных IP-геосервисов могут различаться значительно. Объектом данного исследования выступают общедоступные IP-геосервисы, предоставляющие услуги по IP-геопривязке узлов глобальной сети на основе их IP-адресов, а именно – их точность и полнота. Выборка IP-геосервисов для тестирования были сформирована из числа наиболее популярных [5]. При проведении исследования результаты IP-геолокации сравнивались с достоверными сведениями о расположении некоторых IP-адресов, в качестве показателей точности использовались страна, город и географические координаты. На основе сравнительного анализа результатов тестирования были сделаны выводы о точности IP-геосервисов по выбранным показателям, их существенным свойствам, а также о зависимости ошибки геолокации от размера населенного пункта. Для повышения точности IP-геопривязки авторами предложен ансамблевый метод усреднения координат, полученных от нескольких IP-геосервисов.

**Ключевые слова:** сеть Интернет, IP-геолокация, IP-геосервисы, Atlas, IpAPI, Shodan.

**1. Введение.** В приложении к IP-адресам задача геолокации может быть рассмотрена как процесс сопоставления глобального сетевого адреса устройства с его географическим местоположением. В настоящее время для адресации в глобальной сети используется два адресных пространства: IPv4 и IPv6. Количество пользователей и, соответственно, сетевых устройств постоянно растет и стандарт IPv6 был разработан специально для решения данной проблемы. Однако сложности перехода к новой версии протокола маршрутизации пока что позволяют IPv4 оставаться, по факту, основным [6]. Сетевое пространство в данный момент целиком регламентируется и определяется Администрацией адресного пространства Интернет

(IANA), которая распределяет весь набор IP-адресов между 5 региональными интернет-регистраторами (RIR). В свою очередь каждый из них предоставляет свои подсети интернет-провайдерам различного уровня. Таким образом, адресное пространство в административном плане представляет собой четкую иерархическую структуру.

В то же время стандарты IP [7] не привязывают значение адреса к географическому положению. Верно и обратное — не существует общепринятого стандарта по распределению IP-адресов на основе геоположения узла. В результате два хоста, расположенные в одном доме, могут иметь IP-адреса из разнесенных областей адресного пространства (в качестве меры разноса допустимо применить взвешенное евклидово расстояние [8] — чем старше бит IP-адреса, тем он «важнее»). Противоположное утверждение также истинно — соседние IP-префиксы могут принадлежать операторам связи на разных континентах.

Сложившаяся система распределения адресных ресурсов привела к тому, что пространство IP-адресов, будучи спроецировано на поверхность Земли, не является гладким и представляет собой «лоскутное одеяло» с множеством точек разрыва.

Усложняют ситуацию и современные «облачные» подходы к назначению IP-адресов сетевым интерфейсам. Крупные сетевые операторы используют технологии распределения своей сети, такие как IP Anycast [9] и Content Delivery Network [10]. Зачастую они размещают свое сетевое оборудование, имеющее один и тот же IP-адрес, на разных континентах (рисунок 1). Такой подход позволяет учитывать региональные особенности и условия предоставления услуг, а также ускорить доступ к ресурсам. Примерами являются распределенные по всему миру серверы Google, Netflix, Amazon и других известных корпораций. С точки зрения IP-геолокации такой подход к построению сетей вносит некоторые сложности — один и тот же IP-адрес, используемый разными серверами, будет соотноситься различными IP-геосервисами с различными местами его расположения и ошибка может достигать нескольких тысяч километров.

IP-геолокация предполагает определение географического расположения, привязку к странам, населенным пунктам или другим объектам. Основное применение полученных при геопривязке данных — сфера услуг и маркетинг. Зачастую веб-страницы предлагают рекламу товаров и автоматически устанавливают язык, а службы доставки товаров автоматически заполняют поля в формируемом заказе [11]. Как правило, эти данные получены на основании IP-

геолокации устройства, а не с помощью спутниковых или мобильных систем определения местоположения.

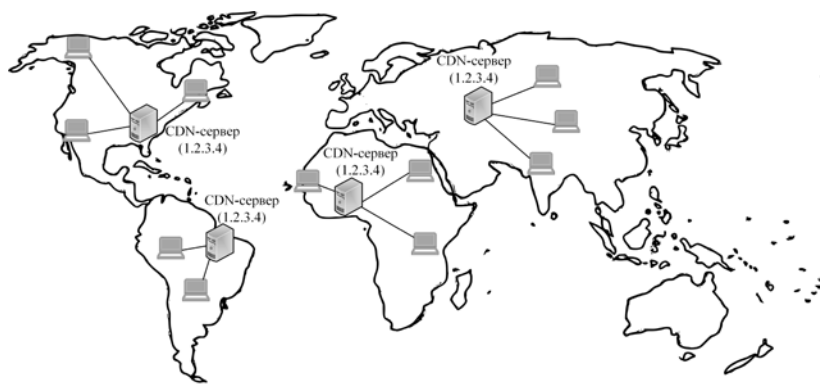


Рис. 1. Зоны обслуживания серверов при использовании технологии Content Delivery Network

IP-геопривязка используется и в технологии GeoDNS [12]. Она, также как и IP Anycast, позволяет распределить сетевую нагрузку, влияя на путь прохождения трафика. Однако в случае GeoDNS маршрутизация трафика осуществляется в зависимости от географической, а не логической удаленности адресата. Сервер GeoDNS содержит несколько A-записей для домена, каждая из которых соответствует одному IP-адресу согласно RFC 1035. Какая именно из A-записей попадет в ответ GeoDNS-сервера зависит от того, в какой географической локации расположен адресат – будет выбран ближайший сервер домена. Такой подход позволяет предлагать пользователям разных стран различный контент в зависимости от их предполагаемых потребностей и интересов, а также уменьшить сетевую задержку между клиентом и сервером.

Другой сферой применения IP-геолокации является информационная безопасность. Поскольку расположение абонентского устройства является одним из свойств его владельца [13, 14], оно используется многими приложениями в процессе многофакторной аутентификации и при значительных отличиях между текущими и обычными значениями координат может служить причиной отказа системы безопасности в доступе к аккаунту [15].

Современные методы IP-геолокации в основном используют метод измерения времени прохождения пакетов до исследуемого узла из известных точек и дальнейшему вычислению координат на их

основе [16]. Точность вычисленных значений может значительно отличаться в зависимости от многих факторов: количество узлов, с которых проводится исследование; их удаленность от определяемого устройства; вид линии связи, по которой проходит пакет. В ходе проведения исследования была обнаружена закономерность: в крупных городах местоположение определяется с точностью до района или улицы, в то время как в малонаселенных районах погрешность может составлять несколько сотен километров.

Однако существуют и другие способы IP-геолокации, основанные на анализе информации о провайдере целевого IP-адреса, а также содержимого веб-страниц. Также местоположение может быть определено по информации из ресурсных записей DNS сервера, которые часто содержат названия стран, городов или других известных мест, например, коды аэропортов [17, 18].

Важным источником данных о геопривязке IP-адресов служат личные данные пользователей онлайн-сервисов доставки. При заказе товара указывается точное местоположение покупателя, которое может быть сопоставлено с его сетевым адресом. Данный факт объясняет более точную геопривязку IP-адресов, находящихся в пользовании частных лиц, а не организаций.

IP-геопривязка конечных подсетей пользователей значительно отличается от той же задачи для подсетей интернет-провайдеров [19]. Это связано с большей географической сосредоточенностью устройств, используемых одной организацией (в пределах одного или нескольких зданий) или физическим лицом, с одной стороны, и распределением подсетей интернет-провайдеров по значительной территории – с другой. Как следствие – определение местоположения IP-адреса только на основании сведений о провайдере, которому он принадлежит, не представляется возможным.

Отдельные IP-геосервисы в зависимости от условий запроса могут давать результаты с высокой точностью, но показатели точности разных IP-геосервисов могут значительно отличаться на различных континентах, в разных странах и регионах. Таким образом, взаимное дополнение результатов IP-геолокации, полученных от различных источников, по мажоритарному принципу с учетом их сильных и слабых сторон позволит скомпенсировать ошибку и получить более точные результаты в среднем.

В соответствии с обозначенными проблемами, целью данного исследования является поиск направлений повышения точности IP-геолокации на основе данных, предоставляемых открытыми IP-геосервисами. IP-геолокация не является новым направлением

исследования глобальной сети Интернет, однако должное внимание стало уделяться данной проблеме сравнительно недавно. Большая часть работ в области IP-геолокации носит эмпирический характер, а количество теоретических материалов ограничено. Одним из перспективных направлений исследования является разработка ансамблевых методов уточнения координат, полученных от разных (в том числе и внешних в широком смысле) IP-геосервисов. Такие методы должны учитывать сильные и слабые стороны каждого из IP-геосервисов.

Задачи исследования: оценка полноты баз данных IP-геосервисов и точности IP-геолокации на уровне страны, на уровне города и на уровне географических координат; определение зависимости точности IP-геопривязки от размера населенного пункта, в котором расположен сетевой узел; разработка предложений по повышению точности IP-геолокации.

Для проведения исследования были отобраны несколько наиболее используемых [5] IP-геосервисов, предоставляющих услуги IP-геолокации. Анализ характеристик каждого из них проводился путем сравнения с достоверной информацией. В качестве априорных сведений были выбраны данные, полученных из системы измерения Интернет пространства Atlas [20]. Зонды данного сервиса имеют привязку к местоположению с точностью не хуже нескольких сотен метров, а их свойства доступны в открытом виде для зарегистрированных пользователей системы. Информация о географическом расположении задается и гарантируется владельцем зонда. Данные геопривязки, предоставленные различными IP-геосервисами, сравнивались с информацией о зондах данного сервиса. На основе результатов тестирования была подсчитана и проанализирована статистика ошибок, позволяющая сформулировать выводы о точности рассмотренных IP-геосервисов.

**2. Анализ области исследования.** Основная часть работ по геолокации IP-адресов связана с рассмотрением различных методов определения местоположения. Как правило, они связаны с выработкой комплексных подходов, учитывающих как семантические данные (ресурсные записи серверов DNS, адреса и почтовые индексы, указанные на web-страницах), так и результаты измерений временных и пространственных метрик [21-23]. Полученные результаты сравниваются, в основном, с данными из коммерческой базы данных GeoIP2 [24]. Такой подход значительно снижает репрезентативность исследований за счет возможного наличия недостоверных сведений в самой GeoIP2, в то время как сравнение с достоверно известными

местоположениями выглядит более убедительно [25, 26]. Стоит отметить, что оценке существующих IP-геосервисов уделено недостаточно внимания, публикации по данной теме содержат устаревшие данные [26].

Известны работы [25-28], в которых проводится подробный анализ IP-геосервисов по методике, аналогичной использованной в данной работе, в них за основу сравнения также берутся данные о местоположении IP-адресов на уровне страны, города и координаты. Эти показатели позволяют описывать местоположение как с точки зрения крупных абстракций (страна и город), так и с точки зрения математических вычислений (координаты). Большинство IP-геосервисов приводят информацию именно в таком формате (использование данных о административном делении стран или почтовых индексах, которые также встречаются в ответах – затруднено по техническим причинам). Отличия данного исследования заключаются в (а) использовании информации о расположении зондов системы Atlas для оценивания точности IP-геосервисов, (б) исследовании зависимости качества IP-геолокации от размера населенного пункта и (в) разработке способа улучшения результатов IP-геолокации путем вычисления координат местоположения сетевого устройства с использованием информации от нескольких IP-геосервисов.

### 3. Используемые данные

**3.1. Выбор IP-геосервисов.** В качестве IP-геосервисов были выбраны популярные web-приложения, имеющие собственный API, что значительно упростило процесс сбора данных (Таблица 1).

Таблица 1. Сравнение характеристик популярных сервисов IP-геолокации

| Название | Регистрация  | Ограничения по количеству запросов (в бесплатной версии) | Стоимость платной подписки в месяц               | Задержка [5, 29-31] |
|----------|--------------|--|--|---------------------|
| IpApi    | Не требуется | 45 запросов в минуту                                     | €13.3/ месяц (количество запросов не ограничено) | Около 50 мс         |
| IpWhois  | Не требуется | 10 тысяч запросов в месяц                                | \$10 .99/ месяц (250 тысяч запросов в месяц)     | Около 600 мс        |

*Продолжение Таблицы 1*

|                                   |              |                           |   |               |
|-----------------------------------|--------------|---------------------------|---|---------------|
| BigDataCloud                      | Требуется    | 10 тысяч запросов в месяц | \$3 за каждые 10 тысяч запросов           | Около 20 мс   |
| BGPView                           | Не требуется | Не ограничено             | -   | Не указана    |
| Shodan                            | Требуется    |                           | \$49 - единократно                        | Не указана    |
| IpGeoLocation                     | Требуется    | 300 запросов в день       | £4.99 / месяц (50 тысяч запросов в день)  | Около 45 мс   |
| Spott                             | Требуется    | 10 тысяч запросов в месяц | \$10/ месяц (10 тысяч запросов)           | Около 600 мс  |
| IpSquads                          | Требуется    | 1000 запросов в месяц     | \$5.99/ месяц (50 тысяч запросов в месяц) | Около 350 мс  |
| IpLocation                        | Требуется    | 1000 запросов в месяц     | \$5/ месяц (50 тысяч запросов в месяц)    | Около 1630 мс |
| IpGeolocation And ThreatDetection | Требуется    | 1500 запросов в день      | \$10/ месяц (2500 тысячи запросов в день) | Около 70 мс   |

**3.2. Данные об узлах с известной геопозицией.** Для того чтобы иметь возможность оценивать точность того или иного IP-геосервиса, необходимо протестировать его на выборке с заранее известными истинными параметрами.

Требования к выборке:

1. Сетевые узлы должны быть рассредоточены по всей территории исследуемого региона;
2. С каждым IP-адресом должна быть сопоставлена достоверная информация о географическом расположении (страна, населенный пункт и координаты);
3. Актуальность информации на момент проведения исследования.

Самым точным способом является создание своей сети либо использование доверенных сетевых устройств, расположение которых можно проверить лично. Другой способ получить проверенные данные – использовать сторонний авторитетный источник. К таковым относятся системы PlanetLab [32] и Atlas. Первый источник – сеть

распределенных по всему миру устройств, использующихся для различных измерений в сети. Данная система поддерживается крупными организациями и учебными заведениями, однако не предоставляет общего доступа для всех желающих, поэтому ее использование в данном исследовании невозможно. Сервис для измерения интернет пространства Atlas – это сеть размещенных по всему миру исследовательских зондов, заявку на установку которых может подать каждый желающий (рисунок 2).



Рис. 2. Расположение зондов системы Atlas на территории России [33]

Архитектура системы Atlas включает:

- слой измерения – распределенная сеть зондов (probes) и анкеров (anchors), отвечающих за выполнение *встроенных* измерений и *пользовательских* измерений (user-defined measurements, UDM);
- слой управления – сервера, отвечающие за работоспособность слоя измерения, хранение и анализ данных, аутентификацию пользователей и т.д.

Работа системы основана на взаимной выгоде ее владельцев и интернет-пользователей: пользователь может подать заявку и, при выполнении определенных условий, безвозмездно получить специализированное сетевое устройство – зонд. Подключив зонд к сети Интернет, пользователь дает возможность системе Atlas проводить встроенные измерения. В свою очередь, Atlas дает возможность пользователю проводить UDM с использованием любых зондов, зарегистрированных в системе.



Atlas позволяет осуществлять следующие виды UDM: проверка сетевой доступности узлов (ping), трассировка маршрутов (traceroute), разрешение доменных имен (DNS), установление шифрованных соединений (SSL/TLS), получение точного времени (NTP), проверка работоспособности web-серверов (HTTP). Создание UDM и получение результатов возможно двумя способами: вручную через web-интерфейс или через web-API. Второй способ является основным при построении автоматизированных систем на основе Atlas.

На рисунке 3 представлен процесс создания и выполнения UDM типа traceroute. Результат выполнения UDM система Atlas передает пользователю в формате JSON.

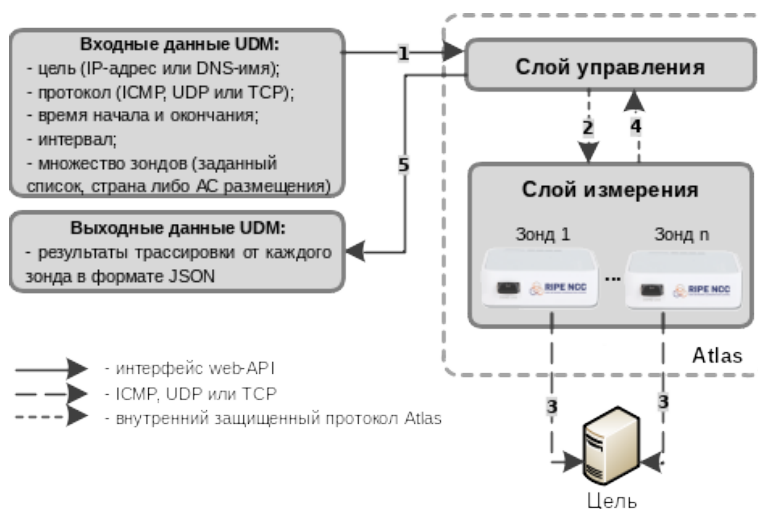


Рис. 3. Процесс создания и выполнения UDM-traceroute

Он является бесплатным и предоставляет API для проведения измерений с помощью зондов. Необходимым условием использования зонда является указание его точной геолокации. Таким образом, система Atlas удовлетворяет предъявляемым требованиям и устройства, входящие в нее, были выбраны в качестве тестовой выборки.

**3.3. Данные о населенных пунктах.** Для получения сведений о зондах системы Atlas использовались API запросы, параметрами которых являлись указывается широта, долгота и радиус зоны поиска. Сервис возвращает список зондов, удовлетворяющих заданным параметрам (рисунок 4).

Для каждого зонда указаны только географические координаты, но не указан город, в котором он находится. Для сопоставления координат зонда и населенного пункта необходимо определить, находятся ли они в его пределах. При данной постановке вопроса целесообразно определить размер города и отправлять запросы с координатой, соответствующей центру города и его радиусом. Известны источники, в которых указана численность населения городов [34], однако источники, содержащие площади малых и средних городов установить не удалось, поэтому формирование значений параметров запросов к системе Atlas осуществлялось на основе математического моделирования.

```

Запрос: GET /api/v2/probes/?radius=53.242688,34.359859:8
широта долгота радиус, км

Ответ: {
  "count": 4, количество найденных зондов
  "results": [
    {
      "address_v4": "77.232.141.222", IPv4-адрес зонда
      "asn_v4": 42145,
      "country_code": "RU", код страны
      "geometry": {
        "type": "Point",
        "coordinates": [
          34.4175, широта зонда
          53.2595 долгота зонда
        ]
      }
    },
    {
      "prefix_v4": "84.42.32.0/19", Подсеть IP-адреса зонда
    }
  ]
}

```

Рис. 4. Пример запроса к системе Atlas и ответа на него

Для создания предсказательной модели была сформирована обучающая выборка, в которую вошли 189 российских городов. Ввиду сравнительно небольшого объема выборки для повышения адекватности модели обучение проводилось с применением кроссвалидации и соотношением training/test равным 80/20. В результате сравнения точности нескольких моделей (линейная регрессия, полиномиальная зависимость, дерево решений, случайный лес) определена лучшая по критерию MSE (minimal square error) –

квадратичная функция (рисунок 5). Предложенная модель не учитывает такие факторы, как уровень технологического развития населенного пункта, его географическое расположение, характер застройки, однако отражает общий характер указанной зависимости.




Рис. 5. ML-модель зависимости площади города от численности его населения

## 4. Проведение исследования

**4.1. Сбор данных о геопозиции зондов.** Для получения данных о зондах системы Atlas необходимо использовать API запрос, параметрами которого являются географическая координата и радиус, в пределах которого они расположены. Большая часть зондов расположена в городах, поэтому в качестве координат были выбраны центры городов с населением более 500 человек из базы данных Geonames [34]. Радиус города определялся исходя из численности его населения по созданной ML-модели. В результате натурального эксперимента на территории России был обнаружен 691 зонд, установлены их координаты и привязка к населенному пункту.

Априорно известно, что на территории России функционирует 530 зондов [35], поэтому следующим этапом была фильтрация данных, так как один зонд мог входить одновременно в несколько зон различных городов. В этом случае предпочтение отдавалось тому населенному пункту, ближе к центру которого расположен зонд (рисунок 6). Каждому зонду сопоставлялся город, а следовательно, и страна, в которых он расположен. В итоге было найдено 412 зондов, расположенных в 181 городе.

Для получения статистики на основе выборки IP-адресов, соответствующих зондам, были сделаны запросы ко всем IP-геосервисам, указанным в таблице №1.




Рис. 6. Расположение зондов на территории населенных пунктов Екатеринбург, Совхозный и Исток. Большинство зондов соотносятся с населенными пунктами. Но, например, зонд с IP-адресом 79.135.68.141 одновременно принадлежит и зоне Екатеринбурга и Совхозного. В данном случае он будет соотнесен с последним, так как находится ближе к его центру

**4.2. Анализ полноты и точности IP-геосервисов.** По результатам анализа измерений были сделаны выводы о характеристиках IP-геосервисов и тенденциях развития IP-геолокации.

**4.2.1. На уровне страны.** Анализ IP-геосервисов по точности и полноте на уровне страны позволяет сделать вывод о том, что данная задача решается с высокой точностью (рисунок 7). Практически безошибочно определить государство по IP-адресу могут все без исключения источники. Однако такие IP-геосервисы как Spott, Shodan, IpGeoLocation и IpLocation явно не являются лидерами по полноте охвата сетевого адресного пространства. Что касается других IP-геосервисов, их базы содержат необходимую информацию о государственной принадлежности почти обо всех тестируемых IP-адресах.

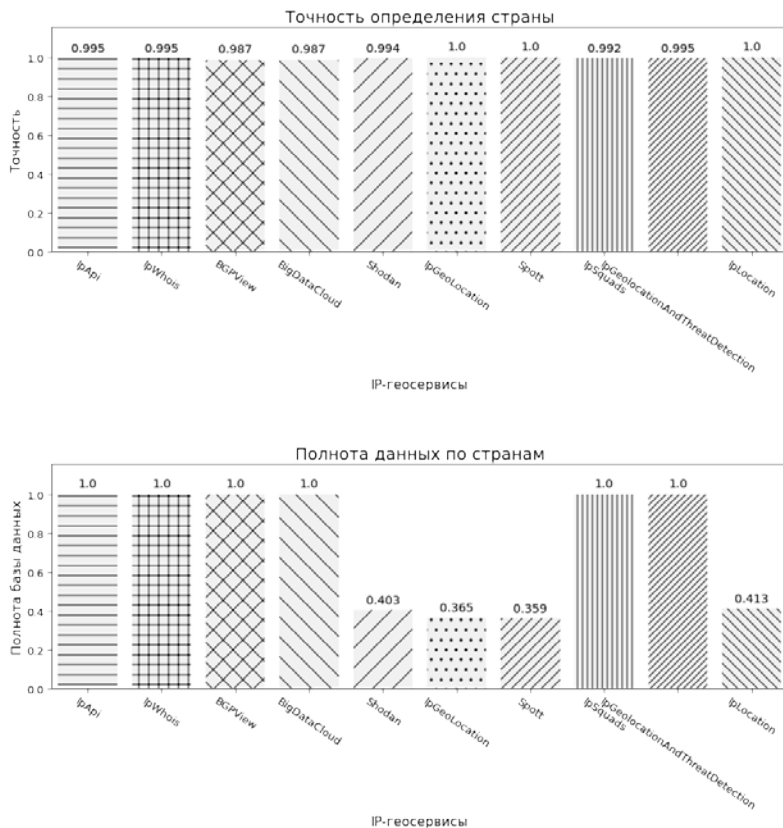


Рис. 7. IP-геолокация на уровне страны

**4.2.2. На уровне города.** Точность определения города для различных IP-геосервисов варьируется в пределах от 39% до 59% за исключением BGPView, который не предоставляет такой информации вовсе. Полнота баз данных почти не отличается от ситуации с определением страны (рисунок 8). Погрешность в измерения вносит написание названия населенного пункта, поскольку оно может быть написано по-разному в том числе и из-за отсутствия единых правил транслитерации. Собранные от разных IP-геосервисов имена городов имеют отличия и при сравнении дают неверный результат. Так, например, город Санкт-Петербург в ряде источников называется 'st-petersburg', в то время как в других значится как 'saint-petersburg'.

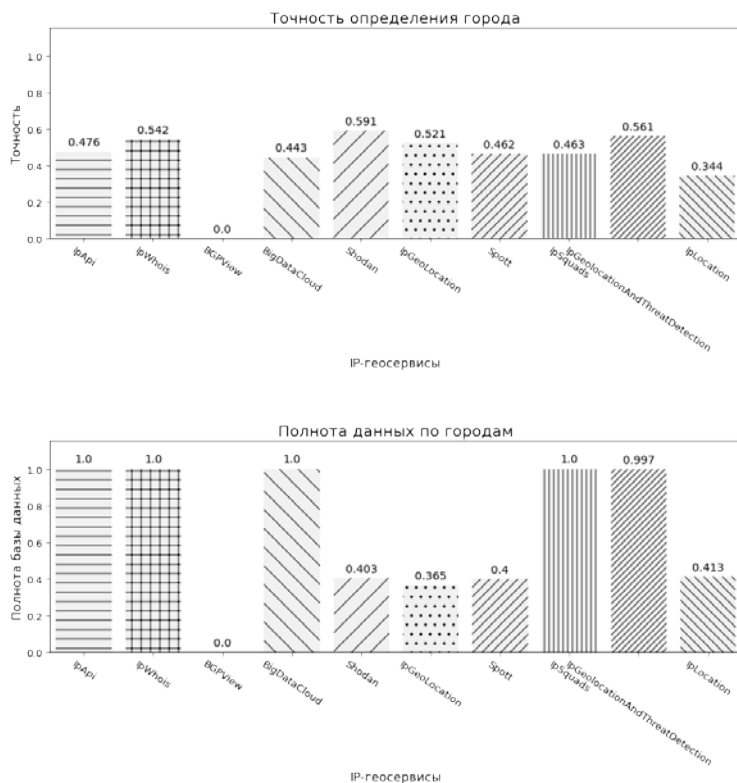


Рис. 8. IP-геолокация на уровне города

По полученным данным можно сделать вывод о том, что полнота базы данных не говорит о ее качестве: Shodan, имея низкие показатели по количеству данных об IP-адресах, показывает довольно высокие результаты по определению города, тогда как у IpSquads ситуация противоположная. Данное качество использовано для назначения уровня «доверия» IP-геосервисам, что позволило увеличить точность IP-геопривязки, используя сильные стороны того или иного источника при обобщении результатов, как показано в пункте 6.

Также частым явлением становится притяжение к более крупному городу. Так, небольшие города вокруг Москвы определялись как Москва. Это может быть связано с отсутствием у IP-геосервисов возможностей для более точного определения местоположения или с отсутствием необходимости иметь настолько точную IP-геопривязку.

Точность определения города по IP-адресу не превышает 60%, однако с учетом различного написания названий городов и притяжения к близко расположенным крупным городам можно обоснованно утверждать, что фактическая IP-геопривязка на уровне городов превышает указанное значение.

**4.2.3. На уровне географических координат.** Анализ точности определения координат проводился на основе данных о разнице между ответом IP-геосервиса и истинными координатами зонда, выраженными в метрической системе. На основании данных вычислений на всей выборке IP-адресов определялся такой критерий как медианное расстояние (рисунок 9). Он соответствует значению, при котором равновероятно появление как больших, так и меньших расстояний.

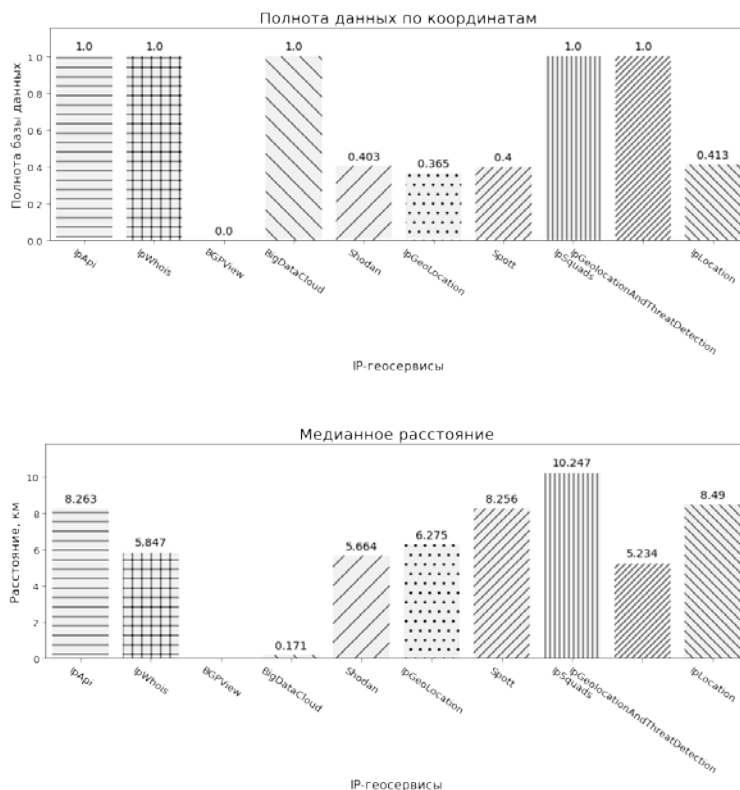


Рис. 9. Статистика определения координаты по IP-адресу

Точность определения координат зонда оценивалась по расстоянию между двумя точками: (а) точкой с истинными координатами зонда и (б) точкой с координатами, полученными от IP-геосервиса. Расстояние измерялось в километрах, было получено 10 выборок (для каждого источника) по 412 значений. Анализ выборок показал, что для них характерно наличие выбросов и распределение значений расстояний не является нормальным. Вследствие этого показателем точности определения координат выбрана медианная ошибка IP-геолокации (MGE – median geolocation error).

Согласно полученным данным наилучший результат показывает BigDataCloud, MGE которого составляет всего около 170 метров. Такая высокая точность может объясняться наличием у разработчиков BigDataCloud информации о расположении зондов системы Atlas, что отчасти подтверждается статьей на веб-странице сервиса [7]. Точность определения координаты рассмотренных IP-геосервисов различна, но у всех из них MGE сопоставимо с размерами среднего города.

Анализ распределения MGE показывает, что координаты большей части IP-адресов из тестовой выборки определяется с ошибкой не более 200-300 км. Однако при более детальном рассмотрении были обнаружены выбросы при значениях 3-4 тыс. км. Это может быть связано с определением координаты IP-адреса как центра страны, в которой он находится. На практике такая ситуация может возникнуть при применении технологии IP Anycast, когда один и тот же IP-адрес принадлежит сразу нескольким устройствам, расположенным на большом удалении друг от друга. В этом случае каждый IP-геосервис будет выбирать только одно из истинных местоположений, внося большую погрешность в результаты измерений.

Анализ рисунка 10 позволяет сделать вывод о том, что большинство IP-геосервисов имеют распределение «с тяжелым хвостом» со смещением влево. Распределения для Spott, IpSquads и IpLocation являются бимодальными со второй модой в области значения MGE 300-1500 километров. Предположительно это связано с отсутствием у данных IP-геосервисов информации о местоположении IP-адреса, кроме его страны нахождения. Распределение BigDataCloud значительно отличается ото всех остальных. Ошибка в определении координат у данного IP-геосервиса не превышает 500 метров практически в 100% случаев. Данный факт может говорить о наличии у BigDataCloud априорных сведений о размещении зондов системы Atlas.



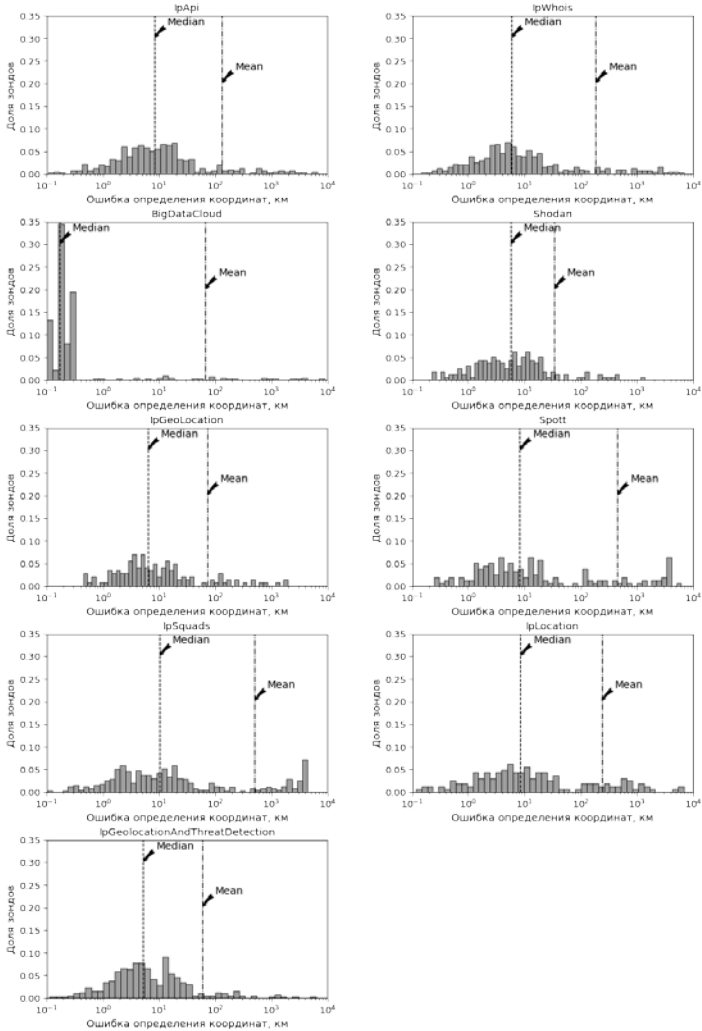


Рис. 10. Гистограммы распределения ошибки определения координат

Для проверки предположения о том, что в больших городах IP-геопривязка точнее, была исследована зависимость расстояния ошибки определения координат от радиуса города. Анализ рисунка 11 позволяет утверждать, что расстояние ошибки обратно пропорциональна размеру города. Так, почти все зонды, расположенные в Москве и Санкт-Петербурге были точно отнесены к

данному месту, в то время как города с радиусом менее 5 км имеют достаточно низкую точность и, вероятно, соответствуют региональному центру.




Рис. 11. Зависимость расстояния ошибки определения координат от размеров населенного пункта

Данный факт может быть объяснен двумя взаимосвязанными феноменами развития сетевой инфраструктуры. Во-первых, большой концентрацией в крупных городах тех сетевых узлов, которые могут быть применены для решения задач IP-геолокации (хостинги, дата-центры, университеты, сетевые энтузиасты). Большое количество измерений, проведенное с «городских» узлов, позволяет снизить влияние отдельных «выбросов» и скомпенсировать систематическую погрешность измерений, вносимую различными типами сетевой инфраструктуры за пределами городов. Во-вторых, опережающим развитием информационного сектора в больших городах и меньшим рассредоточением конечных узлов, что также положительно отражается на качестве IP-геолокации.

**5. Ограничения.** Доступ к ресурсам IP-геосервисов в большинстве случаев ограничен количеством запросов, которые могут быть выполнены в течение месяца. Данный факт накладывает ограничения на объем выборок исследования.

Страна и регион, в котором производятся исследования, оказывают значительное влияние на точность IP-геопривязки. В настоящей работе рассматриваются результаты IP-геолокации только на территории России. Существенные различия в точности определения местоположения наблюдаются как между IP-геосервисами, так и среди данных одного источника в разных регионах. Причины различий в объеме и актуальности баз данных могут заключаться как в возможностях IP-геосервиса по сбору данных на выбранной территории, так и в приоритетности того или иного региона.

Система Atlas позволяет определять геолокацию IP-адресов, присвоенных зондам. Однако информация о местонахождении устройства заполняется его владельцем и в общем случае не может быть достоверной. Погрешность в введении данных, а также умысел владельца могут позволить определить лишь зону, в которой находится зонд. Кроме того, для сохранения конфиденциальности геолокации пользователей сам сервис незначительно изменяет координаты зонда, предоставляемые по запросу, что также негативно сказывается на точности исследования. По доступным данным инструментальная погрешность измерений выдаваемой координаты от истинного местоположения составляет около 100-500 метров, при исключении факта умышленного искажения данных владельцем зонда.

Для формирования значений параметров запросов к системе Atlas была построена ML-модель зависимости между численностью населения города и его площадью. В качестве обучающей выборки

использовались только российские города с населением более 1000 человек, так как количество сетевых устройств в меньших населенных пунктах незначительно, а их площадь отличается несущественно. Радиус города определялся исходя из предположения о том, что он имеет радиально-кольцевую структуру. ML-модель достаточно точно определяет размеры маленьких и средних городов, однако при возрастании численности населения качество результатов деградирует значительно. Это связано с географическим положением и уровнем развития города, преобладающим типом застройки. Так, созданная модель прогнозирует с наибольшей ошибкой площади Санкт-Петербурга и Москвы, в связи с чем в рамках исследования площади данных городов рассчитаны вручную. Таким образом, при необходимости определения площади городов с населением более 1.5 миллионов человек следует использовать детерминированные источники.

**6. Предложения по повышению точности IP-геолокации.** Для повышения точности IP-геолокации авторами предложен ансамблевый метод усреднения координат, полученных от разных IP-геосервисов. При этом каждый ресурс характеризуется коэффициентом, отражающим его точность на данной территории, что позволяет учитывать достоинства и недостатки всех IP-геосервисов.

*Уточнение IP-геопривязки на уровне страны и города*

Из всех ответов IP-геосервисов по мажоритарному принципу выбирается наиболее вероятная страна местонахождения устройства. Источники, ответы которых не совпали с решением большинства, в последующих действиях не учитываются. Аналогично уточняется населенный пункт. В результате остаются только те IP-геосервисы, у которых совпали страна и город в местоположении целевого IP-адреса.

*Уточнение IP-геопривязки на уровне географических координат*

Пусть  $r_i$  – медианная ошибка IP-геолокации  $i$ -го IP-геосервиса.

Тогда уровень доверия  $c_i$  к IP-геосервису может быть выражен как:

$$c_i = 1 - \frac{r_i - \min R}{\max R}, \quad (1)$$

где  $R$  – множество значений медианных ошибок определения местоположения для всех IP-геосервисов.

Вычисление уточненных координат сводится к усреднению координат, полученных от разных IP-геосервисов, и использованию корректирующих слагаемых, рассчитанных на основании уровней

доверия (рисунок 12). Поскольку  $0 < c_i \leq 1$ , каждый IP-геосервис оказывает влияние на значение уточненных координат.

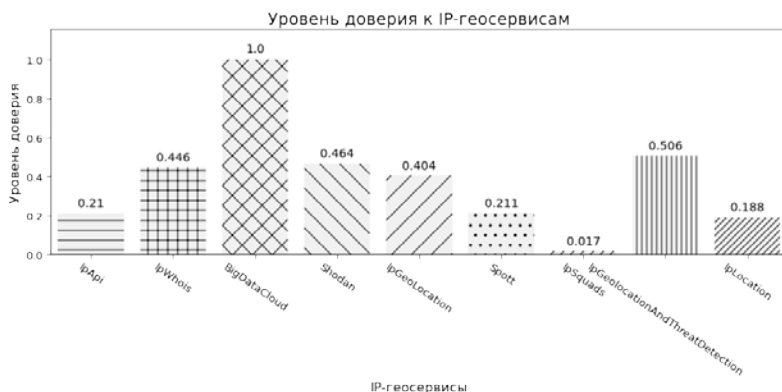


Рис. 12. Уровень доверия к IP-геосервисам

Усредненная широта рассчитывается по формуле (2), а уточненная широта – по формуле (3):

$$lat_{cp} = \frac{1}{R} \sum_{i=1}^{|R|} lat_i, \quad (2)$$

$$lat_{ym} = lat_{cp} + \sum_{i=1}^{|R|} c_i (lat_i - lat_{cp}). \quad (3)$$

Аналогичные формулы используются для расчета долготы. Применение формул (1)-(3) проиллюстрировано на рисунке 13. При вычислении усредненных значений широты и долготы не используются преимущества каждого из IP-геосервисов. В то же время уточненные значения координат лишены этого недостатка за счет использования уровня доверия к IP-геосервисам в качестве коэффициентов, линейно приближающих результирующее значение к показаниям наиболее точных из них.

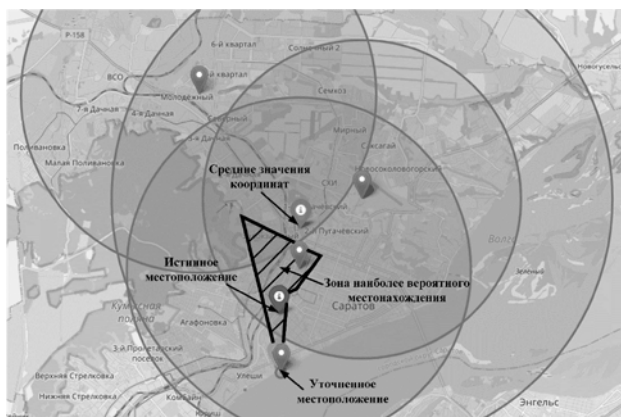


Рис. 13. Иллюстрация предлагаемого метода уточнения IP-геопривязки

Таким образом, на основании данных от нескольких IP-геосервисов уточняется местоположение сетевого устройства на уровнях страны, города и географических координат.

Предложенный метод усреднения координат был проверен экспериментально на зондах системы Atlas на территории России, MGE составила 5.2 км. Данный показатель незначительно превосходит некоторые из IP-геосервисов, при этом позволяет получить более стабильный результат в большем количестве случаев, о чем свидетельствует малое количество выбросов в области более 70 км (рисунок 14). Полученные результаты подтверждают целесообразность применения ансамблевых методов уточнения координат, полученных от разных IP-геосервисов.

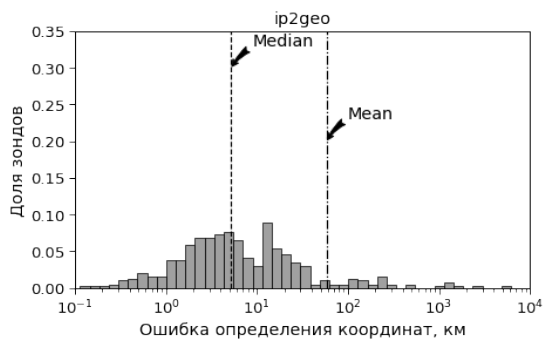


Рис. 14. Гистограммы распределения ошибки определения координат для предлагаемого алгоритма

**7. Заключение.** Информация о местоположении устройства с известным IP-адресом используется при обеспечении информационной безопасности, для оптимизации сетевого трафика, в интернет-маркетинге и других сферах человеческой деятельности, что определяет актуальность задачи IP-геолокации.

Учитывая динамику изменений глобальной сети на уровне интернет-провайдеров, развитие «облачных» сервисов, расширение интернет-аудитории задача IP-геолокации требует как совершенствования измерительной сети, так и развития методик анализа результатов измерений.

В результате исследования получены данные о точности и полноте баз данных наиболее распространенных IP-геосервисов на уровне определения страны, города и координат сетевого устройства. Сформулированы предположения о причинах различных аномалий в результатах IP-геопривязки.

Установлено, что точность IP-геолокации зависит от размера населенного пункта, в котором размещен сетевой узел — при увеличении размера города расстояние ошибки определения координат уменьшается.

Авторами предложен метод повышения точности IP-геолокации, заключающийся в определении страны и города методом простого большинства и вычислении координат с учетом уровня доверия к каждому из рассмотренных IP-геосервисов. Уровень доверия устанавливается в результате сравнительного анализ IP-геосервисов по точности.

Необходимо отметить, что для получения качественного результата IP-геолокации требуется периодическое оценивание основных показателей работы IP-геосервисов, а определение уровня «доверия» должно стать неотъемлемой частью процесса эксплуатации IP-геосервисов.

### **Литература**

1. Wang, Zhihao, et al. "Towards IP Geolocation with Intermediate Routers Based on Topology Discovery." *Cybersecurity*, vol. 2, no. 1, Apr. 2019.
2. Williams J. Identification of IP address using fraudulent geolocation data, Imperial College London, 15 June 2020
3. Wang, Z., Li, H., Li, Q.: Towards IP geolocation with intermediate routers based on topology discovery. *Cybersecurity* 2(1), 1–13 (2019) 5
4. Zhao, Fan & Luo, Xiangyang & Gan, Yong & Zu, Shuodi & Cheng, Qingfeng & Liu, Fenlin. (2018). IP Geolocation based on identification routers and local delay distribution similarity. *Concurrency and Computation: Practice and Experience*. 31. 10.1002/cpe.4722.
5. Top 10 Best IP Geolocation APIs (in 2022) [Электронный ресурс] - Режим доступа: URL: <https://rapidapi.com/blog/ip-geolocation-api/> (21.02.2022)

6. Adebayo, Semiu. Migration of IPv4 to IPv6; Translation Method, 2018.
7. P. Nisenblat, IP Geolocation Demystified [Электронный ресурс] - Режим доступа: URL: <https://www.bigdatacloud.com/blog/ip-geolocation-demystified> (10.12.2021)
8. Measures of distance between samples: Euclidean [Электронный ресурс] - Режим доступа: URL: <http://www.econ.upf.edu/~michael/stanford/maeb4.pdf> (26.11.2021)
9. Zhihao Li, Dave Levin, Neil Spring, and Bobby Bhattacharjee. 2018. Internet anycast: performance, problems, & potential. In Proceedings of the 2018 Conference of the ACM Special Interest Group on Data Communication (SIGCOMM '18). Association for Computing Machinery, New York, NY, USA, 59–73.
10. Aljumaily, Mustafa. (2016). Content Delivery Networks Architecture, Features, and Benefits. 10.13140/RG.2.1.1762.0722
11. Mohammed Jubaer Arif, Shanika Karunasekera, Santosh Kulkarni, Ajit Gunatilaka, and Branko Ristic. 2010. Internet Host Geolocation Using Maximum Likelihood Estimation Technique. In 24th IEEE International Conference on Advanced Information Networking and Applications. IEEE, Perth, Australia, 422-429
12. J. Hawley, "GeoDNS -Geographically-aware, protocol-agnostic load balancing at the DNS level," in Proceedings of the Linux Symposium, pp. 123-130, Linux Symposium Inc., heinäkuu 2009.
13. Сухаревская Е.В. ИССЛЕДОВАНИЕ СИСТЕМ АУТЕНТИФИКАЦИИ // Международный студенческий научный вестник. – 2018. – № 1
14. Аутентификация, основанная на местоположении выхода в интернет [Электронный ресурс] - Режим доступа: URL: <https://studfile.net/preview/16435809/page:4/#8> (02.03.2022)
15. Skrill: инструкция по верификации аккаунта 2022 [Электронный ресурс] - Режим доступа: URL: <https://baxity.com/ru/skrill-instruktsiya-po-verifikatsii-akkaunta-2022> (25.03.2022)
16. Taylor, J., Devlin, J., Curran, K. (2012) Bringing location to IP Addresses with IP Geolocation. The Journal of Emerging Technologies in Web Intelligence, Vol. 4, No. 3, August 2012
17. V.N. Padmanabhan and L. Subramanian. An investigation of geographic mapping techniques for internet hosts. In ACM SIGCOMM, pages 173–185, 2001
18. Ovidiu Dan, Vaibhav Parikh, and Brian D. Davison. 2018. IP Geolocation through Reverse DNS. CoRR abs/1811.04288(2018), 1-10.
19. Luckie, Matthew & Dhamdhare, Amogh & Huffaker, Bradley & Clark, David & claffy, kc. (2016). bdrmap: Inference of Borders Between IP Networks. 381-396. 10.1145/2987443.2987467.
20. RIPE Atlas [Электронный ресурс] - Режим доступа: URL: <https://atlas.ripe.net/> (15.12.2021)
21. Dan, Ovidiu & Parikh, Vaibhav & Davison, Brian. (2018). IP Geolocation through Reverse DNS.
22. Scheitle, Quirin & Gasser, Oliver & Sattler, Patrick & Carle, Georg. (2017). HLOC: Hints-Based Geolocation Leveraging Multiple Measurement Frameworks.
23. Spring, Neil & Mahajan, Ratul & Wetherall, David. (2002). Measuring ISP Topologies with Rocketfuel. ACM SIGCOMM Computer Communication Review. 32. 133-145. 10.1145/633025.633039.
24. GeoIP Databases & Services: Industry Leading IP Intelligence [Электронный ресурс] - Режим доступа: URL: <https://www.maxmind.com/en/geoip2-services-and-databases> (25.01.2022)
25. Gharaibeh, Manaf & Shah, Anant & Huffaker, Bradley & Zhang, Han & Ensafi, Roya & Papadopoulos, Christos. (2017). A look at router geolocation in public and commercial databases. 463-469. 10.1145/3131365.3131380.



26. B. Hufaker, M. Fomenkov, and kc claffy. Geocompare: a comparison of public and commercial geolocation databases. In Proceedings of the Network Mapping and Measurement Conference (NMC), 2011.
27. M. Gouel, K. Vermeulen, O. Fourmaux, T. Friedman, R. Beverly. IP Geolocation Database Stability and Implications for Network Research. Network Traffic Measurement and Analysis Conference, Sep 2021, Online, United States.
28. Du, Ben & Candela, Massimo & Huffaker, Bradley & Snoeren, Alex & claffy, kc. (2020). RIPE IPmap active geolocation: mechanism and performance evaluation. ACM SIGCOMM Computer Communication Review. 50. 3-10. 10.1145/3402413.3402415.
29. IP Geolocation API [Электронный ресурс] - Режим доступа: URL: <https://ip-api.com/> (12.01.2022)
30. Документация по API IP Geolocation API's [Электронный ресурс] - Режим доступа: URL: <https://rapidapi.com/ru/IPSquads/api/ip-geolocation-api-s> (12.01.2022)
31. Документация по API IP Geolocation and Threat Detection [Электронный ресурс] - Режим доступа: URL: <https://rapidapi.com/ru/ipregistry3-ipregistry/api/ip-geolocation-and-threat-detection/> (12.01.2022)
32. PlanetLab Europe [Электронный ресурс] - Режим доступа: URL: <https://www.planet-lab.eu/Home> (19.02.2022)
33. Global RIPE Atlas Network Coverage [Электронный ресурс] - Режим доступа: URL: <https://atlas.ripe.net/results/maps/network-coverage> (22.01.2022)
34. GeoNames [Электронный ресурс] - Режим доступа: URL: <https://www.geonames.org> (26.01.2022)
35. RIPE Atlas Probes [Электронный ресурс] - Режим доступа: URL: <https://atlas.ripe.net/probes/> (14.02.2022)

**Иванов Максим Владимирович** — канд. техн. наук, сотрудник, Академия Федеральной службы охраны Российской Федерации (Академия ФСО России). Область научных интересов: представление и обработка данных в виде графов, методы описания иерархических сетей, применение методов дискретной оптимизации, технологии разработки распределенных программных комплексов. Число научных публикаций — 22. [maximivanov@mail.ru](mailto:maximivanov@mail.ru); улица Приборостроительная, 35, 302015, Орел, Россия; р.т.: +7(4862)549-615.

**Полунин Александр Александрович** — сотрудник, Академия Федеральной службы охраны Российской Федерации (Академия ФСО России). Область научных интересов: архитектуры компьютерных сетей, машинное обучение, разработка приложений, информационная безопасность. Число научных публикаций — 1. [polunin2002@mail.ru](mailto:polunin2002@mail.ru); улица Приборостроительная, 35, 302015, Орел, Россия; р.т.: +7(4862)549-615.

M. IVANOV, A. POLUNIN  
**IMPROVING THE ACCURACY OF IP GEOLOCATION BASED ON  
PUBLIC IP GEOSERVICES DATA**

*Ivanov M., Polunin A. Improving the Accuracy of IP Geolocation Based on Public IP Geoservices Data.*

**Abstract.** IP geolocation is the process of determining the real geographic location of an electronic device connected to the Internet, by its global network address [1]. Currently, it has found wide application in Internet commerce, marketing and advertising, information security [2], and other areas of human activity. There are different methods for determining the location of a remote network device, which differ both in type of analyzed information (delay packet transmission, resource records DNS-servers, the content of Web pages), and the result (country or city name, mail address, probable area of location or exact coordinates) [3, 4]. IP geolocating error depends on the country, population density, type of network device and ranges from several tens of meters to hundreds of kilometers. For the same input data, the results of different IP-geoservices can vary significantly. The object of this study is the public IP-geoservices that provide geolocating services for nodes in the global network based on their IP addresses, and specifically, their accuracy and completeness. The sample of IP-geoservices for testing was formed from the most popular ones [5]. During the study, the results of IP-geolocation were compared with reliable information about the location of some IP addresses, as indicators of accuracy country, city and geographic coordinates were used. Based on the comparative analysis of the test results, conclusions about the accuracy of IP-geolocation services according to the selected indicators, their essential properties, as well as the dependence of geolocation error on the size of the settlement were made. To improve the accuracy of IP georeferencing, the authors proposed an ensemble method for averaging coordinates obtained from several IP geoservices.

**Keywords:** Internet, IP-geolocation, IP-geoservice, Atlas, IpAPI, Shodan.

## References

1. Wang, Zhihao, et al. "Towards IP Geolocation with Intermediate Routers Based on Topology Discovery." *Cybersecurity*, vol. 2, no. 1, Apr. 2019.
2. Williams J. Identification of IP address using fraudulent geolocation data, Imperial College London, 15 June 2020
3. Wang, Z., Li, H., Li, Q.: Towards IP geolocation with intermediate routers based on topology discovery. *Cybersecurity* 2(1), 1–13 (2019) 5
4. Zhao, Fan & Luo, Xiangyang & Gan, Yong & Zu, Shuodi & Cheng, Qingfeng & Liu, Fenlin. (2018). IP Geolocation based on identification routers and local delay distribution similarity. *Concurrency and Computation: Practice and Experience*. 31. 10.1002/cpe.4722.
5. Top 10 Best IP Geolocation APIs (in 2022) - Available at: <https://rapidapi.com/blog/ip-geolocation-api/> (21.02.2022)
6. Adebayo, Semiu. Migration of IPv4 to IPv6; Translation Method, 2018.
7. P. Nisenblat, IP Geolocation Demystified - Available at: <https://www.bigdatacloud.com/blog/ip-geolocation-demystified> (10.12.2021)
8. Measures of distance between samples: Euclidean - Available at: <http://www.econ.upf.edu/~michael/stanford/maeb4.pdf> (26.11.2021)
9. Zhihao Li, Dave Levin, Neil Spring, and Bobby Bhattacharjee. 2018. Internet anycast: performance, problems, & potential. In *Proceedings of the 2018 Conference of the*

- ACM Special Interest Group on Data Communication (SIGCOMM '18). Association for Computing Machinery, New York, NY, USA, 59–73.
10. Aljmaily, Mustafa. (2016). Content Delivery Networks Architecture, Features, and Benefits. 10.13140/RG.2.1.1762.0722
  11. Mohammed Jubaer Arif, Shanika Karunasekera, Santosh Kulkarni, Ajit Gunatilaka, and Branko Ristic. 2010. Internet Host Geolocation Using Maximum Likelihood Estimation Technique. In 24th IEEE International Conference on Advanced Information Networking and Applications. IEEE, Perth, Australia, 422-429
  12. J. Hawley, "GeoDNS -Geographically-aware, protocol-agnostic load balancing at the DNS level," in Proceedings of the Linux Symposium, pp. 123-130, Linux Symposium Inc., heinäkuu 2009.
  13. Suharevskaja E.V. ISSLEDOVANIE SISTEM AVTENTIFIKACII [Authentication systems research]// Mezhdunarodnyj studencheskij nauchnyj vestnik [International student scientific journal] – 2018. – № 1 (In Russ.)
  14. Avtentifikacija, osnovannaja na mestopolozhenii vyhoda v internet [Authentication based on the location of the Internet connection] - Available at: <https://studfile.net/preview/16435809/page:4/#8> (02.03.2022) (In Russ.)
  15. Skrill: instrukcija po verifikacii akkaunta 2022 [Skrill: account verification instructions 2022] - Available at: <https://baxity.com/ru/skrill-instruktsiya-po-verifikatsii-akkaunta-2022> (25.03.2022) (In Russ.)
  16. Taylor, J., Devlin, J., Curran, K. (2012) Bringing location to IP Addresses with IP Geolocation. The Journal of Emerging Technologies in Web Intelligence, Vol. 4, No. 3, August 2012
  17. V.N. Padmanabhan and L. Subramanian. An investigation of geographic mapping techniques for internet hosts. In ACM SIGCOMM, pages 173–185, 2001
  18. Ovidiu Dan, Vaibhav Parikh, and Brian D. Davison. 2018. IP Geolocation through Reverse DNS. CoRR abs/1811.04288(2018), 1-10.
  19. Luckie, Matthew & Dhamdhare, Amogh & Huffaker, Bradley & Clark, David & claffy, kc. (2016). bdrmap: Inference of Borders Between IP Networks. 381-396. 10.1145/2987443.2987467.
  20. RIPE Atlas, Available at: <https://atlas.ripe.net/> (15.12.2021)
  21. Dan, Ovidiu & Parikh, Vaibhav & Davison, Brian. (2018). IP Geolocation through Reverse DNS.
  22. Scheitle, Quirin & Gasser, Oliver & Sattler, Patrick & Carle, Georg. (2017). HLOC: Hints-Based Geolocation Leveraging Multiple Measurement Frameworks.
  23. Spring, Neil & Mahajan, Ratul & Wetherall, David. (2002). Measuring ISP Topologies with Rocketfuel. ACM SIGCOMM Computer Communication Review. 32. 133-145. 10.1145/633025.633039.
  24. GeoIP Databases & Services: Industry Leading IP Intelligence - Available at: <https://www.maxmind.com/en/geoip2-services-and-databases> (25.01.2022)
  25. Gharaibeh, Manaf & Shah, Anant & Huffaker, Bradley & Zhang, Han & Ensafi, Roya & Papadopoulos, Christos. (2017). A look at router geolocation in public and commercial databases. 463-469. 10.1145/3131365.3131380.
  26. B. Huffaker, M. Fomenkov, and kc claffy. Geocompare: a comparison of public and commercial geolocation databases. In Proceedings of the Network Mapping and Measurement Conference (NMC), 2011.
  27. M. Gouel, K. Vermeulen, O. Fourmaux, T. Friedman, R. Beverly. IP Geolocation Database Stability and Implications for Network Research. Network Traffic Measurement and Analysis Conference, Sep 2021, Online, United States.
  28. Du, Ben & Candela, Massimo & Huffaker, Bradley & Snoeren, Alex & claffy, kc. (2020). RIPE IPmap active geolocation: mechanism and performance evaluation.

- ACM SIGCOMM Computer Communication Review. 50. 3-10. 10.1145/3402413.3402415.
29. IP Geolocation API - Available at: <https://ip-api.com/> (12.01.2022)
  30. Dokumentacija po API IP Geolocation API's [IP Geolocation API Documentation] - Available at: <https://rapidapi.com/ru/IPSquads/api/ip-geolocation-api-s> (12.01.2022) (In Russ.)
  31. Dokumentacija po API IP Geolocation and Threat Detection [IP Geolocation and Threat Detection API Documentation] - Available at: <https://rapidapi.com/ru/ipregistry3-ipregistry/api/ip-geolocation-and-threat-detection/> (12.01.2022) (In Russ.)
  32. PlanetLab Europe - Available at: <https://www.planet-lab.eu/Home> (19.02.2022)
  33. Global RIPE Atlas Network Coverage - Available at: <https://atlas.ripe.net/results/maps/network-coverage> (22.01.2022)
  34. GeoNames - Available at: <https://www.geonames.org> (26.01.2022)
  35. RIPE Atlas Probes - Available at: <https://atlas.ripe.net/probes/> (14.02.2022)

**Ivanov Maxim** — Ph.D., Researcher, Academy of Federal Security Guard Service of the Russian Federation. Research interests: graph models, hierarchical networks, discrete optimization, distributed software. The number of publications — 22. [maximivanov@mail.ru](mailto:maximivanov@mail.ru); 35, Priborostroitel'naya St., 302015, Orel, Russia; office phone: +7(4862)549-615.

**Polunin Alexander** — Researcher, Academy of Federal Security Guard Service of the Russian Federation. Research interests: models of the computer networks, machine learning, application development, information security. The number of publications — 1. [polunin2002@mail.ru](mailto:polunin2002@mail.ru); 35, Priborostroitel'naya St., 302015, Orel, Russia; office phone: +7(4862)549-615.

Р.Б. АБДУЛЛАЕВ  
**МЕТОД ОПРЕДЕЛЕНИЯ ФУНКЦИОНАЛЬНОЙ  
ЗАВИСИМОСТИ РАБОЧИХ ВЫХОДОВ ЛОГИЧЕСКИХ  
КОМБИНАЦИОННЫХ СХЕМ ОТ ПРОЯВЛЕНИЯ  
МОНОТОННЫХ ОШИБОК**

*Абдуллаев Р.Б. Метод определения функциональной зависимости рабочих выходов логических комбинационных схем от проявления монотонных ошибок.*

**Аннотация.** В работе исследованы структурные зависимости рабочих выходов логических комбинационных схем с целью последующей идентификации вида возможных ошибок. Приведены виды проявляемых ошибок и классификация рабочих выходов логических комбинационных схем. Показано, что наличие внутренней структурной связи дискретных устройств приводит к увеличению кратности возможных ошибок. Приводится условие определения функциональной зависимости выходов от проявления ошибок исследуемой кратности. Отмечено, что из множества видов ошибок, на выходах схем могут проявляться однонаправленные (монотонные) ошибки. В силу этого, приведен известный метод определения монотонно зависимых рабочих выходов дискретных устройств и указан его недостаток, заключающийся в необходимости только попарного сравнения каждого выхода с остальными из целого множества. Для удобства процесса поиска подобных выходов автором статьи предложен новый метод идентификации монотонно зависимых рабочих выходов, отличающийся от известных методов тем, что данный метод применим для любого числа выходов, что требует значительно меньшего времени для поиска вышеприведенных выходов. Показано, что логические комбинационные схемы могут обладать функциональными особенностями, при которых на рабочих выходах могут проявляться только монотонные ошибки. Следовательно, предложен новый метод идентификации любого числа монотонно независимых рабочих выходов комбинационных схем. Показано, что предлагаемые в статье методы поиска монотонно зависимых и монотонно независимых выходов логических комбинационных схем требуют выполнения несложных математических вычислений. В программной среде Multisim смоделированы внутренние неисправности диагностируемых схем и зафиксированы все возможные ошибки на рабочих выходах. По результатам экспериментов также подтверждена справедливость полученных теоретических результатов.

**Ключевые слова:** комбинационная схема, ошибки на рабочих выходах логических схем, виды ошибок, структурная зависимость рабочих выходов, монотонно зависимые и монотонно независимые рабочие выходы комбинационных схем.

**1. Введение.** Цифровизация любой отрасли жизнедеятельности человечества связана с активным использованием современных вычислительных электронных устройств [1-3]. Строятся подобные устройства в микропроцессорном и микроэлектронном исполнении, в основном, на базе логических схем с памятью и комбинационных схем [3-5].

Логические комбинационные схемы – это множество логических элементов без памяти, взаимосвязанных в определенной степени между собой внутрисхемными связями. Математическое

описание функционирования комбинационных схем составляют булевы функции  $f_j(x)$  [6]. В комбинационных схемах выходная функция  $f_j$  мгновенно меняет свое значение при изменении значения входного сигнала  $x$  по правилам функционирования схемы.

Причиной неверного значения сигнала на рабочем выходе комбинационной схемы может являться неисправность одного (или нескольких) логических элементов. Наиболее часто на выходах логических элементов встречаются константные неисправности (*stuck-at faults*) типа  $const = 1$  или  $const = 0$  [7-10]. Данные искажения могут проявляться на рабочие выходы комбинационной схемы и исказить выходные значения функций.

При синтезе систем управления и контроля ответственными технологическими процессами ставится задача обеспечения высокого уровня надежности и безопасности функционирования их узлов. Эта задача решается различными способами, к примеру, резервированием компонентов и узлов системы, реализацией самопроверяемых структур отдельных узлов для контроля правильности вычисляемых ими функций, применением методов последовательного сканирования схем с памятью, тестированием блоков и узлов и т.д. [9-10]. При проектировании систем с самопроверяемыми структурами часто используют кодовые методы их реализации. В данном случае значения логических сигналов на рабочих выходах диагностируемой схемы представляются в виде информационного вектора кодового слова, а контрольной схемой и генератором вырабатываются контрольные разряды, которые сопоставляются схемой сравнения.

Реальные логические устройства в силу особенностей построения их внутренней структуры могут проявлять только определенные виды ошибок. Учет структур диагностируемых устройств и использование помехозащищенных кодов в основе систем функционального контроля позволяет снизить аппаратные показатели структурной избыточности систем, чем при методе дублирования диагностируемых блоков и узлов. В силу этого, задачам синтеза надежных дискретных устройств с самопроверяемыми структурами, в которых учитываются структурные зависимости выходов устройств на проявление определенных видов ошибок на рабочих выходах, посвящено большое число работ [11-16, 18-26].

К примеру, в работах [18-20] авторы рассматривают вопросы применения кодов Бергера [21] и их модификаций в основе системы функционального контроля структурно зависимых выходов логических комбинационных схем, на которых могут возникать только однонаправленные ошибки, т.е. когда возможны переходы только  $1 \rightarrow$

0 или только  $0 \rightarrow 1$ . Таким образом достигается полное обнаружение всех возможных ошибок на выходах диагностируемых устройств. Данный метод неэффективен при проявлении на выходах схем разнонаправленных ошибок при равном числе переходов типа  $0 \rightarrow 1$  и  $1 \rightarrow 0$ . В [19, 22, 23] изучены методы построения систем функционального контроля логических комбинационных схем с проявлениями на выходах разнонаправленных ошибок и их обнаружения помехозащищенным кодом. Для этой цели в [19] авторами предложен новый код с эффективным обнаружением вышеприведенных ошибок. Недостатком данного способа является не обнаружение ошибок больших кратностей, а также высокая структурная избыточность системы функционального контроля.

В работах [24-26] исследован метод логического дополнения при проектировании систем функционального контроля комбинационных схем, при котором хорошо обнаруживаются только однонаправленные ошибки на выходах схем. Также разработаны методы преобразования структур логических устройств [26, 27] с целью появления на рабочих выходах ошибок только определенных видов для последующего их обнаружения помехозащищенным кодом в основе системы функционального контроля. Таким образом достигается полное обнаружение ошибок на выходах диагностируемых устройств. Однако для преобразования структур устройств требуется внесение значительной аппаратной избыточности помимо избыточности схем контроля, и не для всех диагностируемых устройств удастся применить данный способ синтеза.

В работах [28-30] авторы рассматривают вопросы применения циклических (полиномиальных) кодов для задач функционального диагностирования логических комбинационных схем с учетом свойств рассматриваемых кодов. Авторами предложены способы синтеза систем функционального контроля с обнаружением любых ошибок на выходах дискретных устройств с учетом анализа структуры диагностируемых устройств.

Во всех вышеперечисленных работах, в которых учитывается топология объекта диагностирования, требуется использование конкретных методов определения функциональных зависимостей рабочих выходов от проявления ошибок конкретных видов. К примеру, существующий метод определения функциональной зависимости от проявления однонаправленных ошибок [16] обладает недостатком, заключающийся в необходимости только попарного сравнения каждого выхода с остальными из исследуемого множества,

что при большом числе выходов устройства усложняет задачу поиска таких выходов.

Работа посвящена разработке методов определения структурно зависимых рабочих выходов логических комбинационных схем, на которых могут проявляться однонаправленные ошибки для задач синтеза контролепригодных дискретных схем.

**Постановка задачи.** Каждой комбинационной схеме свойственны собственные особенности перехода и проявления неисправностей, возникающих на выходах логических элементов. Прохождение входного сигнала через несколько логических элементов, наличие разветвлений в структуре, а также функциональных особенностей схемы и т.п., усложняют анализ предсказуемых ошибок на выходах схем. Заранее определив виды возникающих ошибок на выходах исследуемых комбинационных схем, можно предпринимать меры по их устранению еще на этапе проектирования системы функционального контроля и тем самым, достичь полного обнаружения ошибок на данных выходах [13, 19, 23]. Все это требует использование конкретных методов выявления как вида, так и кратности возможных ошибок.

В данной работе поставлена следующая задача: разработать методы определения функциональной зависимости любого числа рабочих выходов логических комбинационных схем на проявление однонаправленных ошибок с целью последующей полной идентификации данных искажений соответствующими кодами, используемых в основе системы функционального контроля логических устройств.

**2. Функциональная зависимость рабочих выходов логических устройств от проявления ошибок определенной кратности.** Как описывалось выше, неисправности логических устройств могут проявляться через ошибки на выходах схемы. В зависимости от структуры устройства неисправность может проявляться на один выход или несколько выходов одновременно. Это определяет кратность ошибки на рабочих выходах –  $d$ ,  $d = \overline{1, m}$ , где  $m$  – число выходов схемы.

На рисунке 1 показана логическая комбинационная схема, которая имеет логический элемент  $G_1$ , выход которого связан с несколькими рабочими выходами схемы –  $f_1$ ,  $f_2$  и  $f_3$ . Данные выходы являются структурно зависимыми и в данном случае, при возникновении неисправности на выходе элемента  $G_1$ , последняя может одновременно проявляться на несколько выходов схемы.



*Определение 1.* Выходы логической комбинационной схемы  $\{f_1, f_2, \dots, f_i\}$ ,  $i \leq t$ , называются *структурно зависимыми*, если в структуре дискретного устройства существует хотя бы один логический элемент, выходы которого связаны с рабочими выходами  $\{f_1, f_2, \dots, f_i\}$ .

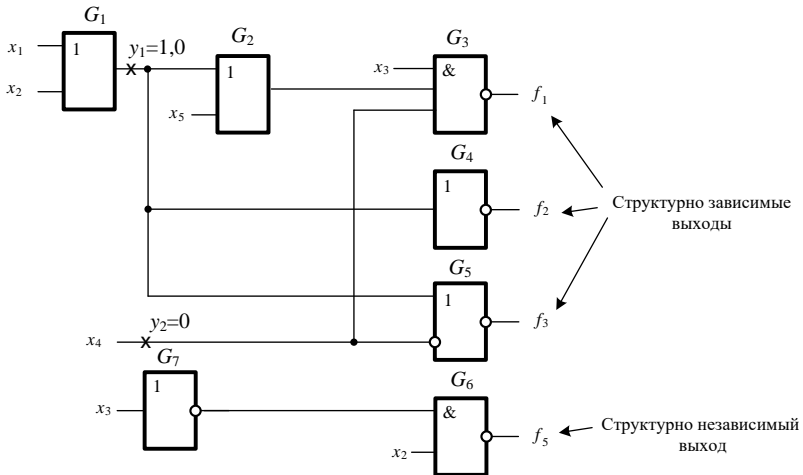


Рис. 1. Комбинационная схема

Наличие структурной зависимости выходов не гарантирует проявление внутренней неисправностей одновременно на всех структурно зависимых выходах. В этом случае вводится понятие функциональной зависимости рабочих выходов логических комбинационных схем на проявление ошибок кратностью  $d$ .

*Определение 2.* Множество выходов логической комбинационной схемы называется *функционально зависимо от возникновения ошибки кратностью  $d$* , если логическая структура устройства, помимо наличия внутренней структурной связи с выходами  $n$ , где  $n \geq d$ , имеет функциональную зависимость от одновременного проявления ошибок на выходах, число которых равно  $d$ .

Для определения кратности возможной ошибки на подобных выходах удобно пользоваться выражением [16, 17]:

$$\frac{df_i}{dy_i} \cdot \frac{df_j}{dy_j} \cdot \dots \cdot \frac{df_d}{dy_d} \neq 0, \quad (1)$$

где  $\frac{df_i}{dy_i}$  – условие проявления неисправности на выходе логического элемента, реализующего функцию  $y_i(x)$ , на рабочий выход  $f_i$ ,  $t \in \{1; q\}$ ;  $q$  – количество элементов в логической схеме;  $d$  – число выходов, определяющее кратность ошибки.

Если произведение условий трансляции внутренней неисправности в точке  $y_i$  для рассматриваемых выходов не равно нулю, то одновременная трансляция неисправности на эти выходы возможна, иначе – на данных выходах невозможно возникновение ошибок кратностью  $d$ , или на данных выходах возможно возникновение ошибок, кратность которых меньше  $d$ .

Условие выражения (1) справедливо для любого значения  $d$ .

К примеру, для схемы на рисунке 1 определим, могут ли проявляться ошибки  $d = 3$  на выходах  $f_1$ ,  $f_2$  и  $f_3$ , при возникновении неисправностей в точке  $y_1$ . Условия трансляции будут определяться следующим образом:

$$\begin{aligned} \frac{df_1}{dy_1} &= \overline{(x_1 \vee x_2 \vee x_5)} x_3 x_4 \oplus \overline{(x_1 \vee x_2 \vee x_5)} x_3 x_4 = \overline{(0 \vee x_5)} x_3 x_4 \oplus \overline{(1 \vee x_5)} x_3 x_4 = \\ &= \overline{x_5} x_4 x_3 \oplus x_3 x_4 = 1 \oplus x_5 x_4 x_3 \oplus 1 \oplus x_3 x_4 = x_3 x_4 (x_5 \oplus 1) = x_3 x_4 \bar{x}_5. \end{aligned}$$

$$\frac{df_2}{dy_1} = \overline{x_1 \vee x_2} \oplus \overline{x_1 \vee x_2} = \bar{0} \oplus \bar{1} = 1.$$

$$\frac{df_3}{dy_1} = \overline{x_1 \vee x_2 \vee \bar{x}_4} \oplus \overline{x_1 \vee x_2 \vee \bar{x}_4} = \overline{0 \vee \bar{x}_4} \oplus \overline{1 \vee \bar{x}_4} = \bar{\bar{x}_4} \oplus 0 = x_4.$$

На основе выражения (1) имеем:

$$\frac{df_1}{dy_1} \cdot \frac{df_2}{dy_1} \cdot \frac{df_3}{dy_1} = x_3 x_4 \bar{x}_5 \cdot 1 \cdot x_4 = x_3 x_4 \bar{x}_5 \neq 0.$$

Следовательно, на выходах  $f_1$ ,  $f_2$  и  $f_3$  могут проявляться ошибки  $d = 3$  при возникновении неисправности на выходе элемента  $G_1$ .

При возникновении неисправности на выходе элемента  $G_7$  неисправность может проявляться только на выход  $f_5$ . Такие выходы получили название абсолютно независимых выходов.

*Определение 3.* Множество выходов логической комбинационной схемы называются *абсолютно независимыми*, если в структуре схемы не существуют логические элементы, пути от которых структурно связаны с более чем одним выходом схемы, а значит, подобные выходы реализуются отдельными подсхемами логического устройства (выход  $f_3$  на рисунке 1).

Наличие в схеме только абсолютно независимых выходов при одиночных внутренних неисправностях обеспечивает возникновение ошибок кратностью только  $d = 1$ .

**3. Виды ошибок на выходах логических комбинационных схем.** Интерес представляют виды ошибок, возникающих на выходах логических устройств. При возникновении многократных ошибок, последние подразделяются на однонаправленные, когда возможны ошибки вида только  $0 \rightarrow 1$  или только  $1 \rightarrow 0$ , и разнонаправленные, когда возможны ошибки и  $0 \rightarrow 1$  и  $1 \rightarrow 0$ . В работе [31] приводится полная классификация видов ошибок, возникающих на рабочих выходах логических устройств.

*Определение 4.* Ошибка называется *монотонной*, если в исследуемом векторе  $\langle f_1, f_2, \dots, f_m \rangle$  происходит переход только вида  $1 \rightarrow 0$  или только вида  $0 \rightarrow 1$ .



Рис. 2. Пример возникновения монотонной ошибки

*Определение 5.* Ошибка называется *симметричной*, если в исследуемом векторе  $\langle f_1, f_2, \dots, f_m \rangle$  происходит одинаковое число переходов вида  $1 \rightarrow 0$  и вида  $0 \rightarrow 1$ .




Рис. 3. Пример возникновения симметричной ошибки

*Определение 6.* Ошибка называется *асимметричной*, если в исследуемом векторе  $\langle f_1, f_2, \dots, f_m \rangle$  происходит неравное число переходов вида  $1 \rightarrow 0$  и вида  $0 \rightarrow 1$ .




Рис. 4. Пример возникновения асимметричной ошибки

В зависимости от структуры и функциональных особенностей исследуемых комбинационных схем на рабочих выходах могут возникать любые из вышеперечисленных видов ошибок.

**4. Виды функциональной зависимости рабочих выходов логических комбинационных схем.** Структура логического устройства определяет значение сигнала рабочего выхода при трансляции внутренней неисправности на данный выход. При анализе в совокупности нескольких подобных выходов отражается полная картина возможных видов ошибок на структурно зависимых выходах схем. На основе множества видов ошибок, приведенного в предыдущем разделе, функционально зависимые выходы логических комбинационных схем имеют следующую классификацию (рисунок 5) [13-16].

*Определение 7.* Выходы логической комбинационной схемы называются монотонно зависимыми, если помимо ошибок другого вида на этих выходах могут возникать и монотонные ошибки.

*Определение 8.* Выходы логической комбинационной схемы называются симметрично зависимыми, если помимо ошибок другого вида на этих выходах могут возникать и симметричные ошибки.

*Определение 9.* Выходы логической комбинационной схемы называются асимметрично зависимыми, если помимо ошибок другого вида на этих выходах могут возникать и асимметричные ошибки.

*Определение 10.* Выходы логической комбинационной схемы называются монотонно независимыми, если на этих выходах могут возникать только монотонные ошибки.

*Определение 11.* Выходы логической комбинационной схемы называются симметрично независимыми, если на этих выходах могут возникать только симметричные ошибки.

*Определение 12.* Выходы логической комбинационной схемы называются асимметрично независимыми, если на этих выходах могут возникать только асимметричные ошибки.

Часто на практике встречаются логические комбинационные схемы со структурно зависимыми выходами, на которых виды ошибок могут сочетаться, например, на асимметрично зависимых выходах могут проявляться и монотонные или симметричные ошибки. Следовательно, функционально зависимые выходы могут иметь еще и следующие виды зависимости.

*Определение 13.* Выходы логической комбинационной схемы называются монотонно асимметрично независимыми, если на этих выходах могут возникать только монотонные и асимметричные ошибки.



Рис. 5. Классификация выходов логических комбинационных схем

*Определение 14.* Выходы логической комбинационной схемы называются монотонно симметрично независимыми, если на этих выходах могут возникать только монотонные и симметричные ошибки.

На рисунке 5 приведена классификация рабочих выходов комбинационных схем. Данная классификация основана на видах и кратности ошибок, возникающих на выходах схем.

**5. Метод определения монотонно зависимых выходов логических комбинационных схем.** Как приводилось выше, зависимые выходы логических комбинационных схем, на которых помимо ошибок другого вида могут также возникать монотонные ошибки, называются *монотонно зависимыми*. Из [16] известно и доказано условие определения возникновения монотонных ошибок только на двух структурно зависимых выходах:

$$\frac{df_i}{dy_i} \cdot \frac{df_j}{dy_i} (f_i \oplus f_j) = 0, \quad (2)$$

где  $f_i$  и  $f_j$  – два структурно зависимых выхода комбинационной схемы.

Левый множитель выражения (2) определяет те входные наборы, при которых осуществляется проявление внутренней неисправности в точке  $y_i$  на рабочие выходы  $f_i$  и  $f_j$ . Правый множитель есть проверка вида ошибки, то есть, при исправной схеме и равных значениях выходов, результат сложения по модулю два будет равным нулю, что соответственно приравняет к нулю результат умножения левого и правого множителей выражения (2). Иначе говоря, если при исправной схеме логический сигнал в точке  $y_i$  проявляется на оба рабочих выхода при подаче тестового входного набора и значения этих выходов получаются одинаковыми, то при внутренней неисправности в рассматриваемой точке искаженный сигнал также будет проявляться на данные выходы, при этом, изменяя значения разрядов одновременно обоих выходов, что соответственно говорит о возникновении монотонной ошибки.

Попарным сравнением всех выходов схемы можно идентифицировать все выходы, на которых могут возникать монотонные ошибки. Однако такой способ является неудобным при большом числе зависимых выходов исследуемой схемы и процесс идентификации видов зависимости выходов усложняется.

Для удобства анализа функциональной зависимости рабочих выходов от проявления монотонных ошибок автором статьи разработан метод идентификации любого числа таких выходов.

*Теорема 1.* Множество выходов  $\{f_{i_1}, f_{i_2}, \dots, f_{i_d}\}$ ,  $d \leq m$ , где  $m$  – число рабочих выходов логической комбинационной схемы, монотонно зависимы, если выполняется условие:

$$\frac{df_{i_1}}{dy_{i_1}} \frac{df_{i_2}}{dy_{i_2}} \dots \frac{df_{i_d}}{dy_{i_d}} \left( \overline{f_{i_1} f_{i_2} \dots f_{i_d} \oplus \overline{f_{i_1} f_{i_2} \dots f_{i_d}}} \right) \neq 0, \quad (3)$$

где  $\frac{df_{i_1}}{dy_{i_1}} \frac{df_{i_2}}{dy_{i_2}} \dots \frac{df_{i_d}}{dy_{i_d}}$  – условие, определяющее искажение кратностью  $d$ , при возникновении неисправности на выходе логического элемента, реализующего функцию  $y_i(x)$ ;  $\overline{f_{i_1} f_{i_2} \dots f_{i_d} \oplus \overline{f_{i_1} f_{i_2} \dots f_{i_d}}}$  – условие, позволяющее выявить, является ли ошибка кратностью  $d$  монотонной или нет.

*Доказательство.* Левая часть выражения (3) определяет, возможны ли на множестве выходов ошибки кратностью  $d$ , т.е. определяются входные наборы, при котором возможно проявление внутренней неисправности на множество  $d$  выходов. Если определены входные наборы – условия трансляции внутренней неисправности для каждого рабочего выхода схемы из множества  $d$ , то, осуществляя перемножение данных наборов по законам алгебры логики, получаем их произведение. Если результат произведения не равен нулю, тогда значение входных наборов таковы, что обеспечивают проявление внутренней неисправности одновременно на все выходы из множества  $d$ . Если произведение равно нулю, следовательно, некоторые входные наборы содержат одинаковые аргументы, но противоположны по значению, или вовсе проявление внутренней неисправности на данное множество  $d$  выходов невозможно.

Правая часть выражения (3) определяет вид искажения на множестве выходов  $d$ . Допустим, что функции множества выходов  $\{f_{i_1}, f_{i_2}, \dots, f_{i_d}\}$ ,  $d \leq m$ , где  $m$  – число выходов комбинационной схемы, при внутренней неисправности принимают неравные значения. Тогда, подставляя числовые значения по закону нулевого множества, получаем:  $f_{i_1} \wedge f_{i_2} \wedge \dots \wedge f_{i_d} = 0 \Rightarrow \overline{f_{i_1} \wedge f_{i_2} \wedge \dots \wedge f_{i_d}} = 1$ , а значит,  $f_{i_1} \wedge f_{i_2} \wedge \dots \wedge f_{i_d} \neq \overline{\overline{f_{i_1} \wedge f_{i_2} \wedge \dots \wedge f_{i_d}}}$ . Следовательно,

$(f_{i_1} \wedge f_{i_2} \wedge \dots \wedge f_{i_d}) \oplus (\overline{f_{i_1} \wedge f_{i_2} \wedge \dots \wedge f_{i_d}}) = 0$  только при неравных значениях аргументов функции неравнозначности.

Допустим, что функции множества выходов  $\{f_{i_1}, f_{i_2}, \dots, f_{i_d}\}$ , при внутренней неисправности принимают равные значения. Тогда результат конъюнкции по закону нулевого множества

$$f_{i_1} \wedge f_{i_2} \wedge \dots \wedge f_{i_d} = 0 \Rightarrow \overline{f_{i_1} \wedge f_{i_2} \wedge \dots \wedge f_{i_d}} = 0, \text{ при значении функций}$$

$f_i = 0, i \in \overline{1, m}$ , и  $f_{i_1} \wedge f_{i_2} \wedge \dots \wedge f_{i_d} = 1 \Rightarrow \overline{f_{i_1} \wedge f_{i_2} \wedge \dots \wedge f_{i_d}} = 1$ , при значении функций  $f_i = 1$ , а значит, в обоих случаях

$$\overline{f_{i_1} \wedge f_{i_2} \wedge \dots \wedge f_{i_d}} = \overline{f_{i_1} \wedge f_{i_2} \wedge \dots \wedge f_{i_d}}. \text{ Отсюда следует,}$$

$(f_{i_1} \wedge f_{i_2} \wedge \dots \wedge f_{i_d}) \oplus (\overline{f_{i_1} \wedge f_{i_2} \wedge \dots \wedge f_{i_d}}) = 1$  только при  $f_{i_1} = f_{i_2} = \dots = f_{i_d}$  функции неравнозначности.

Помимо этого, согласно правилам двойственных функций, при  $f_{i_1} = f_{i_2} = \dots = f_{i_d}$  множество функций  $\{f_{i_1}, f_{i_2}, \dots, f_{i_d}\}$  двойственно множеству функции  $\{\overline{f_{i_1}}, \overline{f_{i_2}}, \dots, \overline{f_{i_d}}\}$ , а значит,

$$f_{i_1} \wedge f_{i_2} \wedge \dots \wedge f_{i_d} = \overline{\overline{f_{i_1} \wedge f_{i_2} \wedge \dots \wedge f_{i_d}}}. \square$$

К примеру, для схемы на рисунке 1, при возникновении неисправности типа  $const=1$  на выходе элемента  $G_1$ , имеем:

$$\begin{aligned} \frac{df_1}{dy_1} \frac{df_2}{dy_1} \frac{df_3}{dy_1} \left( \overline{f_1 f_2 f_3 \oplus \overline{f_1 f_2 f_3}} \right) &= x_3 x_4 \overline{x_5} \left( \overline{f_1 f_2 f_3 \oplus \overline{f_1 f_2 f_3}} \right) = \\ &= x_3 x_4 \overline{x_5} \left( \overline{0 \cdot 0 \cdot 0 \oplus 1 \cdot 1 \cdot 1} \right) = x_3 x_4 \overline{x_5} \cdot 1 = x_3 x_4 \overline{x_5} \neq 0. \end{aligned}$$

При возникновении неисправности типа  $const=0$  на выходе элемента  $G_1$ , имеем:

$$\begin{aligned} \frac{df_1}{dy_1} \frac{df_2}{dy_1} \frac{df_3}{dy_1} \left( \overline{f_1 f_2 f_3 \oplus \overline{f_1 f_2 f_3}} \right) &= x_3 x_4 \overline{x_5} \left( \overline{f_1 f_2 f_3 \oplus \overline{f_1 f_2 f_3}} \right) = \\ &= x_3 x_4 \overline{x_5} \left( \overline{1 \cdot 1 \cdot 1 \oplus 0 \cdot 0 \cdot 0} \right) = x_3 x_4 \overline{x_5} \cdot 1 = x_3 x_4 \overline{x_5} \neq 0. \end{aligned}$$



Значит, зависимость выходов  $f_1$ ,  $f_2$  и  $f_3$  удовлетворяет условиям теоремы 1 при возникновении неисправности на выходе элемента  $G_1$ , следовательно, на данных выходах могут возникать монотонные ошибки.

**6. Метод определения монотонно независимых выходов логических комбинационных схем.** Зависимые выходы логических комбинационных схем, на которых могут возникать только монотонные ошибки, получили название *монотонно независимых*.

Как и при монотонно зависимых рабочих выходах определение монотонно независимых групп выходов можно осуществить с помощью выражения (2), только в данном случае, необходимо также попарное сравнение каждого выхода с остальными. При большом количестве выходов задача считается трудоемкой и требует значительного времени для выявления зависимостей исследуемых выходов.

Группа выходов может быть монотонно независима, если условие выражения (3) выполняется относительно каждого логического элемента внутренней структуры исследуемого устройства, выходы которого связаны с рабочими выходами из множества  $d$ . Следовательно, определяя зависимости рабочих выходов относительно каждого элемента, можно сделать вывод о том, являются ли рабочие выходы монотонно независимыми или нет.

*Теорема 2.* Множество выходов  $\{f_{i_1}, f_{i_2}, \dots, f_{i_d}\}$ ,  $d \leq m$ , где  $m$  – число рабочих выходов логической комбинационной схемы, монотонно независимы, если выполняется условие:

$$\frac{df_{i_1}}{dy_t} \frac{df_{i_2}}{dy_t} \dots \frac{df_{i_d}}{dy_t} \left( \overline{f_{i_1} f_{i_2} \dots f_{i_d}} \oplus \overline{\overline{f_{i_1} f_{i_2} \dots f_{i_d}}} \right) \neq 0, \quad t \in \overline{1, q}, \quad (4)$$

относительно каждого внутреннего элемента устройства, выход которого структурно связан с рабочими выходами схемы из множества  $d$ .

В выражении (4)  $q$  – число логических элементов устройства, выходы которых структурно связаны с рабочими выходами из множества  $d$ ;  $\frac{df_{i_1}}{dy_t} \frac{df_{i_2}}{dy_t} \dots \frac{df_{i_d}}{dy_t}$  – условие, определяющее искажение кратностью  $d$  при возникновении внутренней неисправности на выходе логического элемента, реализующего функцию  $y_t(x)$ ;

$f_{i_1} f_{i_2} \cdot \dots \cdot f_{i_d} \oplus \overline{f_{i_1} f_{i_2} \cdot \dots \cdot f_{i_d}}$  – условие, позволяющее выявить, является ли ошибка кратностью  $d$  монотонной или нет.

*Доказательство.* Левая часть выражения (4) определяет, возможны ли на множестве выходов ошибки кратностью  $d$ , т.е. определяются входные наборы, при которых возможно проявление внутренней неисправности на множестве  $d$  выходов. При этом если условие левой части выражения не выполняется относительно каждого значения  $t$ , то значение  $d$  уменьшают на  $d - n$ ,  $n = 1, 2, 3, \dots$ , и осуществляют проверку выполнения условия для каждого полученного значения  $d$ . Если определены входные наборы – условия проявления внутренней неисправности для каждого рабочего выхода схемы из множества  $d$ , то, осуществляя перемножение данных наборов по законам алгебры логики, получаем их произведение. Если результат произведения не равен нулю, тогда значение входных наборов таковы, что обеспечивают проявление внутренней неисправности одновременно на выходы из множества  $d$ . Если произведение равно нулю, следовательно, некоторые входные наборы содержат одинаковые аргументы, но противоположны по значению, или вовсе проявление внутренней неисправности на данное множество  $d$  выходов невозможно.

Справедливость правой части выражения (4) основано на доказательстве теоремы 1.

К примеру, для схемы на рисунке 1 при возникновении неисправности типа  $const=0$  в точке  $y_2$  (неисправность типа обрыв), получаем:

$$\frac{df_1}{dy_2} \frac{df_3}{dy_2} \left( \overline{f_1 f_3} \oplus \overline{\overline{f_1} \overline{f_3}} \right) = \overline{x_1} \overline{x_2} x_3 x_5 \left( \overline{1 \cdot 0} \oplus \overline{0 \cdot 1} \right) = 0.$$

Значит, зависимость выходов  $f_1$  и  $f_3$  не удовлетворяет условиям теоремы 2 при возникновении неисправности в точке  $y_2$ . Рабочие функции  $f_1$  и  $f_3$  в данном случае формируют разные значения, следовательно, данные ошибки не монотонные. Формируемые ошибки являются симметричными.

Таким образом, на основе выражений (3) и (4) рабочие выходы  $f_1$ ,  $f_2$  и  $f_3$  не являются монотонно независимыми, т.к. помимо монотонных ошибок на данных выходах могут возникать и симметричные ошибки.

Рассмотрим другую комбинационную схему, выходы которой также имеют структурную зависимость (рисунок 6).

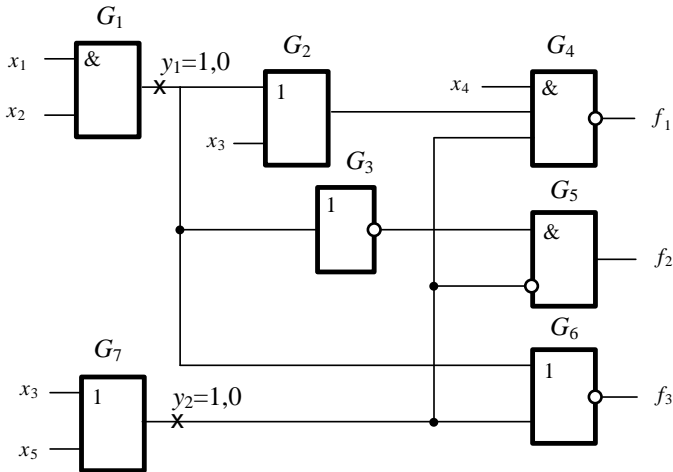


Рис. 6. Комбинационная схема с монотонно независимыми выходами

Определим условия одновременного проявления внутренней неисправности относительно точки  $y_2$  на зависимые выходы  $f_1, f_2$  и  $f_3$ :

$$\begin{aligned} \frac{df_1}{dy_1} &= \overline{(x_1 x_2 \vee x_3) x_4 (x_3 \vee x_5)} \oplus \overline{(x_1 x_2 \vee x_3) x_4 (x_3 \vee x_5)} = \\ &= \overline{x_3 x_4 (x_3 \vee x_5)} \oplus \overline{x_4 x_3 \vee x_4 x_5} = \\ &= \overline{x_3 x_4 \vee x_3 x_4 x_5 x_3 x_4 \vee x_4 x_5 \vee x_3 x_4 \vee x_3 x_4 x_5 x_3 x_4 \vee x_4 x_5} = \\ &= \overline{x_3 x_4 x_3 x_4 \vee x_4 x_5 \vee x_3 x_4 (x_3 x_4 \vee x_4 x_5)} = \overline{x_3 x_4 x_3 x_4 \vee x_4 x_5 \vee \bar{x}_3 x_4 x_5} = \\ &= \overline{x_3 x_4 x_3 x_4 x_4 x_5 \vee \bar{x}_3 x_4 x_5} = \bar{x}_3 x_4 x_5. \end{aligned}$$

$$\frac{df_2}{dy_1} = \overline{x_1 x_2 x_3 \vee x_5} \oplus \overline{x_1 x_2 x_3 \vee x_5} = \overline{x_3 \vee x_5} \oplus 0 = \bar{x}_3 \bar{x}_5.$$

$$\frac{df_3}{dy_1} = \overline{x_1 x_2 \vee x_3 \vee x_5} \oplus \overline{x_1 x_2 \vee x_3 \vee x_5} = \overline{x_3 \vee x_5} \oplus 0 = \bar{x}_3 \bar{x}_5.$$

$$\frac{df_1}{dy_1} \cdot \frac{df_2}{dy_1} \cdot \frac{df_3}{dy_1} = \bar{x}_3 x_4 x_5 \cdot \bar{x}_3 \bar{x}_5 \cdot \bar{x}_3 \bar{x}_5 = 0.$$

Следовательно, одновременное проявление трехкратных ошибок на исследуемых выходах невозможно. Произведем попарное «сравнение» условий проявления внутренней неисправности на зависимые выходы:

$$\frac{df_1}{dy_1} \cdot \frac{df_2}{dy_1} = \bar{x}_3 x_4 x_5 \cdot \bar{x}_3 \bar{x}_5 = 0; \quad \frac{df_1}{dy_1} \cdot \frac{df_3}{dy_1} = \bar{x}_3 x_4 x_5 \cdot \bar{x}_3 \bar{x}_5 = 0;$$

$$\frac{df_2}{dy_1} \cdot \frac{df_3}{dy_1} = \bar{x}_3 \bar{x}_5 \cdot \bar{x}_3 \bar{x}_5 = \bar{x}_3 \bar{x}_5 \neq 0.$$

Откуда следует, что одновременно на выходах  $f_1$ ,  $f_2$  и  $f_3$  могут возникать только двукратные ошибки на выходах  $f_2$  и  $f_3$  при внутренней неисправности в точке  $y_1$  и подаче входного вектора  $\langle \bar{x}_3 \bar{x}_5 \rangle$ . Также на данных выходах при подаче входного вектора  $\langle \bar{x}_3 x_4 x_5 \rangle$  может возникать одиночная ошибка на выходе  $f_1$ . Затем, на основе выражения (3) определим, являются ли искажения, проявляющиеся при неисправности в точке  $y_1$  на выходах  $f_2$  и  $f_3$  комбинационной схемы на рисунке 6, монотонными: при  $y_1=1$ :

$$\frac{df_2}{dy_1} \frac{df_3}{dy_1} \overline{(f_2 f_3 \oplus \bar{f}_2 \bar{f}_3)} = \bar{x}_3 \bar{x}_5 \overline{(0 \cdot 0 \oplus 1 \cdot 1)} = \bar{x}_3 \bar{x}_5 \neq 0,$$

при  $y_1=0$ :

$$\frac{df_2}{dy_1} \frac{df_3}{dy_1} \overline{(f_2 f_3 \oplus \bar{f}_2 \bar{f}_3)} = \bar{x}_3 \bar{x}_5 \overline{(1 \cdot 1 \oplus 0 \cdot 0)} = \bar{x}_3 \bar{x}_5 \neq 0.$$

Следовательно, для комбинационной схемы на рисунке 6 при неисправностях типа  $y_1 = 1$  и  $y_1 = 0$  на рабочих выходах возникают двукратные монотонные ошибки.

Такие же условия определим относительно точки  $y_2$ : при  $y_2 = 1$ :

$$\frac{df_1}{dy_2} \cdot \frac{df_2}{dy_2} \cdot \frac{df_3}{dy_2} = \bar{x}_1 x_3 x_4 \vee \bar{x}_2 x_3 x_4 \overline{(0 \cdot 0 \cdot 0 \oplus 1 \cdot 1 \cdot 1)} \neq 0,$$

при  $y_2 = 0$ :

$$\frac{df_1}{dy_2} \cdot \frac{df_2}{dy_2} \cdot \frac{df_3}{dy_2} = \bar{x}_1 x_3 x_4 \vee \bar{x}_2 x_3 x_4 (1 \cdot 1 \cdot 1 \oplus 0 \cdot 0 \cdot 0) \neq 0.$$

По результатам вычислений следует вывод, что при внутренних неисправностях в точках  $y_1$  и  $y_2$  логической комбинационной схемы на рисунке 5 на рабочих выходах могут возникать только монотонные ошибки. При проявлении других неисправностей диагностируемой схемы, исходя из структуры, возможны возникновения только одиночных ошибок. Следовательно, выходы  $f_1, f_2$  и  $f_3$  рассматриваемой схемы являются монотонно независимыми.

**7. Экспериментальные результаты.** Для подтверждения корректности предложенного метода определения монотонно зависимых и монотонно независимых рабочих выходов логических комбинационных устройств для выше рассмотренных схем (рисунок 1 и рисунок 6) в среде Multisim были смоделированы константные неисправности на выходах внутренних логических элементов и зафиксированы все возможные виды ошибок на рассматриваемых выходах схем.

Для логической комбинационной схемы, приведенной на рисунке 1, были поочередно введены константные неисправности на выходе логического элемента  $G_1$  (рисунок 7) типа  $y_1 = 1$  и  $y_1 = 0$ , а также неисправность типа обрыв на входе  $x_4 - y_2 = 0$ .

Результаты экспериментов для комбинационной схемы, приведенной на рисунке 1, записаны в таблице 1.




Рис. 7. Моделирование неисправностей в среде Multisim в точках  $y_1$  и  $y_2$  внутренней структуры устройства, приведенного на рис. 1

Искаженные значения сигналов на рабочих выходах в таблице 1 выделены жирным. Можно заметить, что при неисправностях типа  $y_1 = 1$  и  $y_1 = 0$  на рабочих выходах  $f_1, f_2$  и  $f_3$  проявляются трехкратные

монотонные ошибки. При неисправности типа  $y_2 = 0$  на выходах  $f_1$  и  $f_3$  проявляются двукратные симметричные ошибки, что и было доказано с помощью введенных выражений (3) и (4). Других ошибок на рабочих выходах схемы при возникновении неисправностей в точках  $y_1$  и  $y_2$  быть не может. Следовательно, выходы рассматриваемой схемы являются монотонно зависимыми.

Таблица 1. Проявление неисправностей комбинационной схемы, приведенной на рисунке 1

| Тестовый входной вектор |       |       |       |       | Значение зависимых выходов при исправной схеме |       |       | Вид неисправности | Значение зависимых выходов при неисправной схеме |       |       |
|-------------------------|-------|-------|-------|-------|--|-------|-------|-------------------|--|-------|-------|
| $x_1$                   | $x_2$ | $x_3$ | $x_4$ | $x_5$ | $f_1$  | $f_2$ | $f_3$ |                   | $f_1$  | $f_2$ | $f_3$ |
| 0                       | 0     | 1     | 1     | 0     | 1  | 1     | 1     | $y_1 = 1$         | 0  | 0     | 0     |
| 1                       | 1     | 1     | 1     | 0     | 0  | 0     | 0     | $y_1 = 0$         | 1  | 1     | 1     |
| 0                       | 0     | 1     | 1     | 1     | 0  | 1     | 1     | $y_2 = 0$         | 1  | 1     | 0     |

Для логической комбинационной схемы, приведенной на рисунке 6, были введены константные неисправности на выходе внутренних логических элементов  $G_1$  и  $G_7$  (рисунок 8).




Рис. 8. Моделирование неисправностей в среде Multisim на выходах логических элементов  $G_1$  и  $G_7$  внутренней структуры устройства, приведенного на рис. 6

Результаты эксперимента для комбинационной схемы, приведенной на рисунке 6, записаны в таблице 2.

Анализируя значения рабочих функций при неисправной схеме, можно заметить, что при неисправностях типа  $y_1 = 1$  и  $y_1 = 0$  на рабочих выходах  $f_1$ ,  $f_2$  и  $f_3$  проявляются одиночные и двукратные монотонные ошибки. При неисправности типа  $y_2 = 0$  проявляются одиночные и трехкратные монотонные ошибки.

Таблица 2. Проявление неисправностей комбинационной схемы, приведенной на рисунке 6

| Тестовый входной вектор |       |       |       |       | Значение зависимых выходов при исправной схеме |       |       | Вид неисправности | Значение зависимых выходов при неисправной схеме |          |          |
|-------------------------|-------|-------|-------|-------|--|-------|-------|-------------------|--|----------|----------|
| $x_1$                   | $x_2$ | $x_3$ | $x_4$ | $x_5$ | $f_1$  | $f_2$ | $f_3$ | 1,0               | $f_1$  | $f_2$    | $f_3$    |
| 0                       | 0     | 0     | 1     | 1     | 1  | 0     | 0     | $y_1 = 1$         | <b>0</b>   | 0        | 0        |
| 1                       | 1     | 0     | 1     | 1     | 0  | 0     | 0     | $y_1 = 0$         | <b>1</b>   | 0        | 0        |
| 0                       | 0     | 0     | 1     | 0     | 1  | 1     | 1     | $y_1 = 1$         | 1  | <b>0</b> | <b>0</b> |
| 1                       | 1     | 0     | 1     | 0     | 1  | 0     | 0     | $y_1 = 0$         | 1  | <b>1</b> | <b>1</b> |
| 0                       | 0     | 1     | 1     | ~     | 0  | 0     | 0     | $y_2 = 0$         | <b>1</b>   | <b>1</b> | <b>1</b> |
| 1                       | 1     | 1     | 1     | ~     | 0  | 0     | 0     | $y_2 = 0$         | <b>1</b>   | 0        | 0        |

Таким образом, на выходах схемы рисунка 6 возможны только монотонные ошибки, а значит, рассматриваемые рабочие выходы  $f_1$ ,  $f_2$  и  $f_3$  являются монотонно независимыми, что и было доказано с помощью выражения (4).

**8. Заключение.** Предложенный в работе метод определения функционально зависимых выходов комбинационных схем позволяет на практике устанавливать типы структур диагностируемых устройств, неисправности которых будут вызывать на рабочих выходах монотонные ошибки. Отличием установленного метода по отношению к известным исследованиям является возможность его применения для любого числа структурно зависимых выходов, при котором сокращается число вычислительных процедур при поиске монотонно зависимых и монотонно независимых групп выходов.

Анализ возникающей неисправности и проявление ее в виде различных видов ошибок на зависимых выходах комбинационных схем позволяет на основе выводов выработать конкретные рекомендации при построении отказоустойчивых схем. Кроме этого, определение вида зависимости рабочих выходов позволяет принимать и другие специальные способы синтеза схем встроенного контроля [31-34] для обнаружения ошибок любых видов на рабочих выходах схем.

### Литература

1. Hahanov V. Cyber-Physical Computing for IoT-driven Services // New York.: Springer International Publishing AG. 2018. 279 p.

2. Kuntsevich V., Gubarev V., Kondratenko Yu., Lebedev D., Lysenko V. Control Systems: Theory and Applications. // River Publishers Series in Automation, Control and Robotics. 2018. 327 p.
3. Wernet M., Brunokowski M., Witt Ph., Meiwald T. Digital tools for relay interlocking diagnostics and condition assessment // DVV Media Group GmbH: SIGNAL + DRAHT. 2019. vol. 111. Issue 11. pp. 39-45.
4. Сапожников Вл.В. Синтез систем управления движением поездов на железнодорожных станциях с исключением опасных отказов // М.: Наука. 2021. 229 с.
5. Drozd O., Rucinski A., Zashcholkin K., Martynyuk O., Drozd J. Resilient Development of Models and Methods in Computing Space // Proceedings of 19th IEEE East-West Design & Test Symposium (EWDTS'2021). 2021. pp. 70-75.
6. Boole G. The Mathematical Analysis of Logic Being an Essay Towards a Calculus of Deductive Reasoning // London.: Cambridge: Macmillan, Barclay, & Macmillan, George Bell. Public domain in the USA. Release date 28 July 2011 y. 87 p.
7. Пархоменко П.П., Согомоян Е.С. Основы технической диагностики (оптимизация алгоритмов диагностирования, аппаратурные средства) // М.: Энергоатомиздат. 1981. 320 с.
8. П.П. Пархоменко. Надежность и эффективность в технике: Справочник в десяти томах. Т.9: Техническая диагностика / под. ред. В.В. Клюева и П.П. Пархоменко // М.: Машиностроение. 1987. 352 с.
9. Сапожников В.В., Сапожников Вл.В., Христов Х.А., Гавзов Д.В. Методы построения безопасных микросистемных систем железнодорожной автоматики / Под ред. Вл. В. Сапожникова // М.: Транспорт. 1995. 272 с.
10. Согомоян Е.С., Слабаков Е.В. Самопроверяемые устройства и отказоустойчивые системы // М.: Радио и связь. 1989. 207 с.
11. Stempkovskiy A.L., Telpukhov D.V., Gurov S.I., Zhukova T.D., Demeneva A.I. R-code for concurrent error detection and correction in the logic circuits // Proceedings of Young Researchers in Electrical and Electronic Engineering (EIconRus'2018). 2018. pp. 1430-1433.
12. Efanov D.V., Abdullaev R.B. Boolean Complement Method to Polynomial Codes for Combinational Circuits Testing // Proceedings of Conference of Russian Young Researchers in Electrical and Electronic Engineering (EIconRus'2022). 2022. pp. 139-144.
13. Efanov D.V., Sapozhnikov V.V., Sapozhnikov Vl.V. Organization of a Fully Self-Checking Structure of a Combinational Device Based on Searching for Groups of Symmetrically Independent Outputs // Automatic Control and Computer Sciences. 2020. vol. 54. no 4. pp. 279-290.
14. Ефанов Д. В. Синтез самопроверяемых комбинационных устройств на основе кодов с эффективным обнаружением симметричных ошибок // Труды СПИИРАН. 2020. № 4, С. 62-91.
15. Sogomonyan E.S., Gössel M. Design of Self-Testing and On-Line Fault Detection Combinational Circuits with Weakly Independent Outputs // Journal of Electronic Testing: Theory and Applications. 1993. vol. 4. no 4. pp. 267-281.
16. Morosow A., Sapozhnikov V.V., Sapozhnikov Vl.V. and Goessel M. Self-Checking Combinational Circuits with Unidirectionally Independent Outputs. VLSI Design. 1998. vol. 5. pp. 333-345.
17. Убар Р. Тестовая диагностика цифровых устройств, I. Таллин.: Таллинский политехнический институт. 1980. 112 с.
18. Ефанов Д.В., Сапожников В.В., Сапожников Вл.В. Условия обнаружения неисправности логического элемента в комбинационном устройстве при



- функциональном контроле на основе кода Бергера // Автоматика и телемеханика. 2017. № 5. С. 152–165.
19. Сапожников В.В., Сапожников Вл.В., Ефанов Д.В. Коды с суммированием, обнаруживающие любые симметричные ошибки // Электронное моделирование. 2017. Том 39. № 3. С. 47–60.
  20. Efanov D.V., Sapozhnikov V.V., Sapozhnikov V.I. Two-Modulus Codes with Summation of One-Data Bits for Technical Diagnostics of Discrete Systems // Automatic Control and Computer Sciences. 2018. vol. 52. Issue 1. pp. 1–12.
  21. Berger J.M. A Note on Error Detecting Codes for Asymmetric Channels // Information and Control. 1961. vol. 4. Issue 1. pp. 68–73.
  22. Сапожников В.В., Сапожников Вл.В., Ефанов Д.В., Абдуллаев Р.Б. Особенности организации систем функционального контроля комбинационных схем на основе полиномиальных кодов // Известия Петербургского университета путей сообщения. 2018. Т. 15. №3. С. 432-446.
  23. Абдуллаев Р.Б. Синтез полностью самопроверяемых схем встроенного контроля на основе полиномиальных кодов для комбинационных логических устройств // Автоматика на транспорте. 2021. №3. С. 452-476.
  24. Goessel M., Morozov A.V., Sapozhnikov V.V., Sapozhnikov V.I. Checking Combinational Circuits by the Method of Logic Complement // Automation and Remote Control. 2005. vol. 66. no. 8, pp. 1336-1346.
  25. Efanov D.V., Sapozhnikov V.V., Sapozhnikov V.I., Pivovarov D.V. Synthesis of Built-in Self-Test Control Circuits Based on the Method of Boolean Complement to Constant-Weight 1-out-of-n Codes // Automatic Control and Computer Sciences. 2019. vol. 53. Issue 6. pp. 481-491.
  26. Das D.K., Roy S.S., Dmitriev A., Morozov A., Gössel M. Constraint Don't Cares for Optimizing Designs for Concurrent Checking by 1-out-of-3 Codes // Proceedings of the 10th International Workshops on Boolean Problems. 2012. pp. 33-40.
  27. Busaba F.Y., Lala P.K. Self-Checking Combinational Circuit Design for Single and Unidirectional Multibit Errors // Journal of Electronic Testing: Theory and Applications. 1994. pp. 19-28.
  28. Сапожников В.В., Сапожников Вл.В., Ефанов Д.В., Абдуллаев Р.Б. О свойствах полиномиальных кодов в системах функционального контроля // Информатика и системы управления. 2018. №2. С. 50-61.
  29. Abdullaev R., Efanov D. Polynomial Codes Properties Application in Concurrent Error-Detection Systems of Combinational Logic Devices // Proceedings of 19th IEEE East-West Design & Test Symposium (EWDTS'2021). 2021. pp. 40-46.
  30. Сапожников В.В., Сапожников Вл.В., Ефанов Д.В., Абдуллаев Р.Б. Полиномиальные коды в системах функционального контроля комбинационных логических схем // Новые информационные технологии в исследовании сложных структур: Материалы 12-й международной конференции. 2018. С. 95-96.
  31. Сапожников В.В., Сапожников Вл.В., Ефанов Д.В. Классификация ошибок в информационных векторах систематических кодов // Известия вузов: Приборостроение. 2015. №5. С. 333-343.
  32. Ubar R., Raik J., Vierhaus H.T. Design and Test Technology for Dependable Systems-on-Chip // New York.: Information Science Reference, Hershey. IGI Global. 2011. 578 p.
  33. Mitra S., McCluskey E.J. Which concurrent error detection scheme to choose? // Proceedings of International Test Conference. 2000. pp. 985–994.
  34. Butorina N. Self-testing checker design for incomplete m-out-of-n codes // Proceedings of 12th IEEE East-West Design & Test Symposium (EWDTS'2014). 2014. pp. 258–261.

35. Borecký J., Kohlík M., Kubátová H. Parity Driven Reconfigurable Duplex System // *Microprocessors and Microsystems*. 2017. vol. 52. pp. 251–260.

**Абдуллаев Руслан Борисович** — канд. техн. наук, доцент, кафедра автоматике и телемеханики, Ташкентский государственный транспортный университет (ТГТУ). Область научных интересов: дискретная математика, надежность и техническая диагностика дискретных систем. Число научных публикаций — 40. ruslan\_0507@mail.ru; улица Темирийулчилар, 1, 100067, Ташкент, Узбекистан; р.т.: +998(90)725-3882.

R. ABDULLAEV

**METHOD FOR DETERMINING THE FUNCTIONAL DEPENDENCES OF WORKING OUTPUTS OF LOGIC COMBINATION SCHEMES FOR DEVELOPMENT UNIDIRECTIONAL ERRORS**

*Abdullaev R. Method for Determining the Functional Dependences of Working Outputs of Logic Combination Schemes for Development Unidirectional Errors.*

**Abstract.** Structural dependences of the working outputs of logical combinational circuits were studied with the aim of subsequent identification of the type of possible errors. The types of manifested errors and the classification of the working outputs of logical combinational circuits are given. It is shown that the presence of an internal structural connection of discrete devices leads to an increase in the multiplicity of possible errors. The condition for determining the functional dependence of outputs on the manifestation of errors of the studied multiplicity is given. It is noted that out of the many types of errors, unidirectional errors can appear at the outputs of the circuits. A well-known method for determining unidirectionally dependent operating outputs of discrete device circuits is presented, which has a drawback. It is only necessary to pairwise compare each output with the rest of the whole set. For the convenience of the process of searching for such outputs, the author of the article proposed a new method for identifying unidirectionally dependent working outputs. This method differs from known methods in that it is applicable for any number of outputs, which requires much less time to search for the above outputs. It is shown that logical combinational circuits can have functional features, in which only unidirectional errors can appear at the working outputs. Therefore, a new method for identifying any number of unidirectionally independent operating outputs of combinational circuits has been proposed. It is shown that the methods proposed in the article for finding unidirectionally dependent and unidirectionally independent outputs of logical combinational circuits require simple mathematical calculations. In the Multisim, internal faults of the diagnosable circuits are simulated and all possible errors at the working outputs are fixed. According to the results of the experiments, the validity of the theoretical results obtained was also confirmed.

**Keywords:** combinational circuit, errors at operating outputs of logic circuits, types of errors, structural dependence of operating outputs, unidirectionally dependent and unidirectionally independent operating outputs of combinational circuits.

**References**

1. Hahanov V. Cyber-Physical Computing for IoT-driven Services. New York.: Springer International Publishing AG, 2018. 279 p.
2. Kuntsevich V., Gubarev V., Kondratenko Yu., Lebedev D., Lysenko V. Control Systems: Theory and Applications. River Publishers Series in Automation, Control and Robotics, 2018. 327 p.
3. Wernet M., Brunokowski M., Witt Ph., Meiwald T. Digital tools for relay interlocking diagnostics and condition assessment. DVV Media Group GmbH: SIGNAL + DRAHT. 2019. vol. 111. Issue 11. pp. 39-45.
4. Sapozhnikov V.I. Sintez sistem upravleniya dvizheniyem poyezdov na zheleznodorozhnykh stantsiyakh s isklyucheniym opasnykh otkazov [Synthesis of train traffic control systems at railway stations with the exception of dangerous failures] M.: Nauka. 2021. 229 p. (in Russ.).

5. Drozd O., Rucinski A., Zashcholkin K., Martynyuk O., Drozd J. Resilient Development of Models and Methods in Computing Space. Proceedings of 19th IEEE East-West Design & Test Symposium (EWDTS'2021). 2021. pp. 70-75.
6. Boole G. The Mathematical Analysis of Logic Being an Essay Towards a Calculus of Deductive Reasoning. London.: Cambridge: Macmillan, Barclay, & Macmillan, George Bell. Public domain in the USA. Release date 28 July 2011 y. 87 p.
7. Parkhomenko P.P., Sogomonyan E.S. Osnovy tekhnicheskoy diagnostiki (optimizatsiya algoritmov diagnostirovaniya, apparaturnyye sredstva) [Fundamentals of technical diagnostics (optimization of diagnostic algorithms, hardware)]. M.: Energoatomizdat. 1981. 320 p. (In Russ.).
8. Parkhomenko P.P. Nadezhnost i effektivnost v tekhnike: Spravochnik v desyati tomakh. T.9: Tekhnicheskaya diagnostika / pod. red. V.V. Klyuyeva i P.P. Parkhomenko [Reliability and efficiency in engineering: A handbook in ten volumes. T.9: Technical diagnostics / under. ed. V.V. Klyuev and P.P. Parkhomenko]. M.: Mashinostroenie. 1987. 352 p. (In Russ.).
9. Sapozhnikov V.V., Sapozhnikov VI.V., Hristov H.A., Gavzov D.V. Metody postroyeniya bezopasnykh mikroelektronnykh sistem zheleznodorozhnoy avtomatiki. Pod red. VI.V. Sapozhnikova [Methods for constructing safe microelectronic systems for railway automation. Edited by VI.V. Sapozhnikov]. M.: Transport. 1995. 272 p. (In Russ.).
10. Soghomonyan E.S., Slabakov E.V. Samoproveryayemyye ustroystva i otkazo-ustoychivyye sistemy [Self-checking devices and fault-tolerant systems]. M.: Radio i svyaz. 1989. 207 p. (In Russ.).
11. Stempkovskiy A.L., Telpukhov D.V., Gurov S.I., Zhukova T.D., Demeneva A.I. R-code for concurrent error detection and correction in the logic circuits. Proceedings of Young Researchers in Electrical and Electronic Engineering (EIConRus'2018). 2018. pp. 1430-1433.
12. Efanov D.V., Abdullaev R.B. Boolean Complement Method to Polynomial Codes for Combinational Circuits Testing. Proceedings of Conference of Russian Young Researchers in Electrical and Electronic Engineering (ElConRus'2022). 2022. pp. 139-144.
13. Efanov D.V., Sapozhnikov V.V., Sapozhnikov VI.V. Organization of a Fully Self-Checking Structure of a Combinational Device Based on Searching for Groups of Symmetrically Independent Outputs. Automatic Control and Computer Sciences. 2020. vol. 54. no 4. pp. 279-290.
14. Efanov D. V. [Synthesis of self-checking combinational devices based on codes with efficient detection of symmetrical errors]. Trudy SPIIRAN – SPIIRAS Proceedings. 2020. №4. pp. 62-91. (In Russ.).
15. Sogomonyan E.S., Gössel M. Design of Self-Testing and On-Line Fault Detection Combinational Circuits with Weakly Independent Outputs. Journal of Electronic Testing: Theory and Applications. 1993. no 4. pp. 267-281.
16. Morosow A., Sapozhnikov V.V., Sapozhnikov VI.V. and Goessel M. Self-Checking Combinational Circuits with Unidirectionally Independent Outputs. VLSI Design. 1998. no 5. pp. 333-345.
17. Ubar R. Test diagnostics of digital devices, I. Tallinn.: Tallinn Polytechnic Institute. 1980. 112 p.
18. Efanov D.V., Sapozhnikov V.V., Sapozhnikov VI.V. [Conditions for Detecting a Logical Element Fault in a Combination Device under Concurrent Checking Based on Berger's Code]. Avtomatika i telemekhanika – Automation and remote control. 2017. vol. 5. pp. 152–165. (In Russ.).

19. Sapozhnikov V.V., Sapozhnikov VI.V., Efanov D.V. [On the class of codes with summation with all symmetric errors detection]. *Elektronnoje Modelirovanije – Electronic modeling*. 2017. Issue 39. vol. 3. pp. 47–60. (In Russ.).
20. Efanov D.V., Sapozhnikov V.V., Sapozhnikov VI.V. Two-Modulus Codes with Summation of One-Data Bits for Technical Diagnostics of Discrete Systems. *Automatic Control and Computer Sciences*. 2018. vol. 52. Issue 1. pp. 1–12.
21. Berger J.M. A Note on Error Detecting Codes for Asymmetric Channels. *Information and Control*. 1961. vol. 4. Issue 1. pp. 68–73.
22. Sapozhnikov V.V., Sapozhnikov VI.V., Efanov D.V., Abdullaev R.B. [Features of the organization of functional control systems for combinational circuits based on polynomial codes]. *Izvestiya Peterburgskogo universiteta putey soobshcheniya – Proceedings of Petersburg Transport University*. 2018. № 3. pp. 432–446. (In Russ.).
23. Abdullaev R.B. [Synthesis of fully self-checking built-in control circuits based on polynomial codes for combinational logic devices]. *Avtomatika na transporte – Automation on transport*. 2021. №3. pp. 452–476. (In Russ.).
24. Goessel M., Morozov A.V., Sapozhnikov V.V., Sapozhnikov VI.V. Checking Combinational Circuits by the Method of Logic Complement. *Automation and Remote Control*. 2005. vol. 66. no. 8. pp. 1336–1346.
25. Efanov D.V., Sapozhnikov V.V., Sapozhnikov VI.V., Pivovarov D.V. Synthesis of Built-in Self-Test Control Circuits Based on the Method of Boolean Complement to Constant-Weight 1-out-of-n Codes. *Automatic Control and Computer Sciences*. 2019. vol. 53. Issue 6. pp. 481–491.
26. Das D.K., Roy S.S., Dmitiriev A., Morozov A., Gössel M. Constraint Don't Cares for Optimizing Designs for Concurrent Checking by 1-out-of-3 Codes. *Proceedings of the 10th International Workshops on Boolean Problems*. 2012. pp. 33–40.
27. Busaba F.Y., Lala P.K. Self-Checking Combinational Circuit Design for Single and Unidirectional Multibit Errors. *Journal of Electronic Testing: Theory and Applications*. 1994. pp. 19–28.
28. Sapozhnikov V.V., Sapozhnikov VI.V., Efanov D.V., Abdullaev R.B. [On the properties of polynomial codes in functional control systems]. *Informatika i sistemy upravleniya – Informatics and control systems*. 2018. №2. pp. 50–61. (In Russ.).
29. Abdullaev R., Efanov D. Polynomial Codes Properties Application in Concurrent Error-Detection Systems of Combinational Logic Devices // *Proceedings of 19th IEEE East-West Design & Test Symposium (EWDTS'2021)*. 2021. pp. 40–46.
30. Sapozhnikov V.V., Sapozhnikov VI.V., Efanov D.V., Abdullaev R.B. [Polynomial codes in functional control systems of combinational logic circuits] *Novyye informatsionnyye tekhnologii v issledovanii slozhnykh struktur: Materialy 12-y mezhdunarodnoy konferentsii [New information technologies in the study of complex structures: Proceedings of the 12th international conference]*. 2018. pp. 95–96. (In Russ.).
31. Sapozhnikov V.V., Sapozhnikov VI.V., Efanov D.V. [Classification of errors in information vectors of systematic codes]. *Izvestiya vuzov: Priborostroenie – Journal of instrument engineering*. 2015. №5. pp. 333–343. (In Russ.).
32. Ubar R., Raik J., Vierhaus H.T. *Design and Test Technology for Dependable Systems-on-Chip*. New York.: Information Science Reference, Hershey. IGI Global. 2011. 578 p.
33. Mitra S., McCluskey E.J. Which concurrent error detection scheme to choose? *Proceedings of International Test Conference*. 2000. pp. 985–994.
34. Butorina N. Self-testing checker design for incomplete m-out-of-n codes. *Proceedings of 12th IEEE East-West Design & Test Symposium (EWDTS'2014)*. 2014. pp. 258–261.

35. Borecký J., Kohlík M., Kubátová H. Parity Driven Reconfigurable Duplex System. *Microprocessors and Microsystems*. 2017. vol. 52. pp. 251–260.

**Abdullaev Ruslan** — Ph.D., Associate professor, Automation and remote control department, Tashkent State Transport University (TSTU). Research interests: discrete mathematics, reliability and technical diagnostics of discrete systems. The number of publications — 40. ruslan\_0507@mail.ru; 1, Temiryulchilar St., 100067, Tashkent, Uzbekistan; office phone: +998(90)725-3882.

А.Н. ПАВЛОВ, Д.А. ПАВЛОВ, А.Б. УМАРОВ, А.В. ГОРДЕЕВ  
**МЕТОД СТРУКТУРНО-ПАРАМЕТРИЧЕСКОГО СИНТЕЗА  
КОНФИГУРАЦИЙ МНОГОРЕЖИМНОГО ОБЪЕКТА**

*Павлов А.Н., Павлов Д.А., Умаров А.Б., Гордеев А.В. Метод структурно-параметрического синтеза конфигураций многорежимного объекта.*

**Аннотация.** Сложность современных объектов с перестраиваемой структурой приводит к необходимости учета различных факторов взаимодействия их с окружающей средой и связана с увеличением числа входящих в их состав элементов и подсистем, а также, соответственно, стремительным ростом числа внутренних связей, и проявляется в таких аспектах, как структурная сложность, сложность функционирования, сложность выбора поведения, сложность моделирования и сложность развития. Данные системы функционируют в условиях существенной неопределённости, связанной с изменением содержания целей и задач, стоящих перед объектом, воздействием возмущающих факторов со стороны внешней среды и имеющих целенаправленный и/или нецеленаправленный характер. Указанные аспекты сложности системы связаны не только с неопределёнными воздействиями внешней среды, но и с множеством различных режимов (видов) функционирования, соответствующих множественности решаемых задач и множественности показателей качества их решения. Как правило, системы с фиксированной структурой, настраиваемые обычно на установившийся (какой-то заданный) режим, не обеспечивают наилучшего качества управления в других режимах. Поэтому многорежимность и неопределённость условий функционирования обуславливают необходимость решения проблемы анализа и синтеза конфигурации и реконфигурации рассматриваемых объектов, основанных на интеллектуальных подходах. При этом на этапах создания и проектирования объектов с перестраиваемой структурой должны быть синтезированы такие взаимосвязанные множества режимов функционирования и структур, а также, возможно, внесён такой уровень избыточности в указанные множества с учетом пространственно-временных, технических и технологических ограничений, при которых на этапе их применения по целевому назначению имелась бы возможность гибко реагировать на все расчётные и нерасчётные нештатные ситуации, вызывающие структурные изменения объекта. С формальной точки зрения, решение указанных задач возможно в рамках такого важнейшего класса современных научно-технических задач, как задачи многокритериального структурно-функционального синтеза конфигураций многорежимных объектов на различных этапах их жизненного цикла. В настоящей статье приведен метод решения указанных задач, основанный на предложенной авторами концепции параметрического генома сложных многорежимных объектов. Применение данной концепции позволяет в концентрированном виде хранить явные и неявные знания экспертов о взаимодействии элементов и подсистем объекта при выполнении различных вариантов реализации режимов функционирования, а также осуществлять оперативное вычисление значений оптимистических и пессимистических оценок показателей структурно-функциональной надежности однородных/неоднородных, монотонных/немонотонных, равноценных/неравноценных многорежимных объектов. Для решения задачи многокритериального выбора требуемого количества недоминируемых вариантов конфигураций многорежимного объекта, равномерно расположенных в множестве эффективных (паретовских) альтернатив, была предложена комбинация метода интервального лексикографического упорядочения (последовательных уступок) и операторного решающего правила. При этом для проведения детального анализа возможности реализации объектом совместного или раздельного взаимодействия

режимов функционирования с равноценной или неравноценной интенсивностью их применения было предложено нечетко-возможностное представление обобщенного показателя структурно-функциональной надежности в виде трапецевидного числа и определения его центра тяжести. Эффективность использования разработанного метода структурно-параметрического синтеза конфигураций многорежимного объекта с перестраиваемой структурой проиллюстрирована на примере решения задачи структурно-параметрического синтеза конфигураций системы управления движением малого космического аппарата «Аист-2Д».

**Ключевые слова:** синтез конфигураций, многорежимный объект, многокритериальность, множество недоминируемых альтернатив, параметрический геном.

---

**1. Введение.** Как правило, современные сложные объекты с перестраиваемой структурой являются многофункциональными (многорежимными), т.е. предназначены для выполнения нескольких различных целевых задач (функций) [1]. Существенными особенностями функционирования таких многорежимных объектов (МрО) являются организация изменения режимов функционирования, в том числе при больших по уровню деструктивных воздействиях, а также ужесточение требований к обеспечению высококачественного управления при реализации каждого режима с целью достижения конечной цели.

На сегодняшний день довольно большую популярность приобретают направления исследований, ориентируемые на выявление и последующее использование альтернативных (байпасных) путей реализации собственных функций элементами и подсистемами МрО в случае возникновения аномальных (нештатных) ситуаций. Подходы, близкие к данному по идее и содержанию, встречаются в работах ряда иностранных авторов [2 – 9]. Одной из наиболее известных концепций, положенных в основу данных подходов, является концепция FDIR (Fault Detection (Обнаружение (отказов)), Isolation (Локализация) and Recovery (Восстановление)). Разработка инновационных механизмов и их внедрение совместно с уже проверенными методами стандартного FDIR, направленными на увеличение времени работы МрО по назначению и сокращению числа переходов в безопасные режимы, говорят о системном подходе в исследованиях, связанных с указанной концепцией [2 – 9]. В зарубежных источниках встречается целый ряд различных определений механизмов FDIR, однако, как правило, современные FDIR системы решают следующие типовые задачи [2 – 9]: обнаружение неисправностей (отказов, ошибок) в системе; локализация возникшей неисправности и отнесение к конкретному типу, а также определение степени её критичности; поиск наилучших путей устранения неисправности для минимизации негативных



последствий и реализация этих путей. Для осуществления подобных подходов необходимым условием является их дополнение новыми технологиями и методами структурно-параметрического синтеза конфигураций МрО, о которых и идет речь в представленной работе.

Следует отметить, что на этапах проектирования, создания и применения МрО при решении задач оценивания, анализа и синтеза конфигурации и реконфигурации таких объектов требуется учитывать различные варианты задействования динамических режимов функционирования, которые существенным образом влияют на структурно-функциональную надежность и живучесть функциональных элементов (ФЭ), подсистем и в целом всего объекта [10, 11]. При этом в самом общем случае ФЭ проектируемых МрО имеют широкую номенклатурную базу для формирования из них тех или иных конфигураций, а ряд ФЭ обладают узкой номенклатурной базой. Необходимо добавить, что при решении задачи конфигурирования МрО на этапе проектирования и создания требуется учитывать, кроме номенклатурной базы ФЭ, различные ограничения, в том числе возможности создания с их помощью функционального резерва (структурно-функциональной избыточности). Созданный резерв обеспечивает гибкое (проактивное) реагирование на возникающие в будущем нештатные ситуации (расчетные и нерасчетные), вызывающие деградацию и реконфигурацию структур сложного объекта [12, 13] на этапе его применения по целевому назначению (реализации режимов функционирования). Однако следует иметь в виду, что на этапах создания и проектирования МрО зачастую невозможно заранее определить совместность/несовместность, а также интенсивность задействования тех или иных режимов его функционирования, которые могут быть реализованы на этапе применения.

Учитывая все выше сказанное, содержательная формулировка исследуемой в данной статье задачи структурно-параметрического синтеза конфигураций МрО сводится к следующему. Требуется осуществить многокритериальный выбор (синтез) эффективных вариантов конфигураций МрО с учетом пространственно-временных, технических и технологических ограничений с целью максимизации показателей структурно-функциональной надежности МрО в условиях неопределенных сценариев реализации циклограмм режимов функционирования [14, 15].

Статья организована следующим образом. В разделе 2 приводится описание применения концепции параметрического генома МрО при оценивании показателей структурно-функциональной

надежности  $MpO$  для различных сценариев реализации режимов функционирования. Математическая постановка задачи структурно-параметрического синтеза конфигураций  $MpO$  приведена в разделе 3. В разделе 4 приводится описание комбинированного метода, включающего в себя совместное применение метода последовательных уступок и операторного решающего правила, для нахождения требуемого количества недоминируемых конфигураций  $MpO$ , равномерно расположенных во множестве Парето. Для детального анализа полученных конфигураций  $MpO$  вводится обобщенное описание количественных показателей структурно-функциональной надежности  $MpO$  для различных сценариев реализации режимов функционирования в виде нечеткого трапециевидного числа, а также его центроид в качестве интегральной оценки рассматриваемого свойства. В разделе 5 описываются основные результаты решения задачи структурно-параметрического синтеза конфигураций системы управления движением (СУД) малого космического аппарата (МКА) дистанционного зондирования Земли (ДЗЗ), которая, несомненно, является одной из важнейших подсистем бортового комплекса управления (БКУ) МКА.

**2. Применение концепции параметрического генома для оценивания показателей структурно-функциональной надежности многорежимных объектов.** Для структурного представления логических условий реализации режимов функционирования  $MpO$  предлагается применить общий логико-вероятностный метод (ОЛВМ), а также программный комплекс логико-вероятностного моделирования (ПК ЛВМ) «Арбитр» [16]. С этой целью при построении схемы функциональной целостности (СФЦ)  $MpO$  наряду с функциональными вершинами, отражающими работоспособность его ФЭ, введем вершины, характеризующие потребности (интенсивности) реализации рассматриваемых режимов функционирования. При этом под интенсивностью задействования режима функционирования будем понимать отношение суммарного времени задействования режима на рассматриваемом интервале времени к величине этого интервала. Очевидно, что в этом случае возможные значения интенсивностей задействования режимов будут заполнять целиком отрезок единичной длины  $[0;1]$ . Тогда при сравнении двух режимов будем называть менее (более) интенсивным тот режим, вычисленное значение указанного отношения которого меньше (больше) второго. После чего осуществим расчет вероятностного полинома успешной реализации режимов функционирования  $MpO$  с учетом совместного и/или несовместного их задействования [15, 17–19].

Идея использования таких вершин состоит в следующем (рисунок 1).

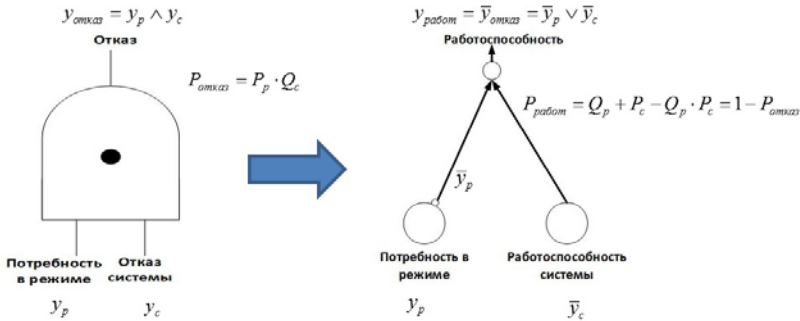


Рис. 1. Фрагмент дерева отказов и СФЦ для режима функционирования

Событие «Отказ выполнения режима» возникает тогда, когда присутствуют события « $y_p$  – есть потребность в режиме» И « $y_c$  – система (объект) не работоспособен», т.е. структурная логическая функция отказа имеет вид  $y_{отказ} = y_p \wedge y_c$ , а соответствующий полином отказа равен  $P_{отказ} = P_p \cdot Q_c$ .

Приведем противоположное событие «Режим выполняется (Работоспособен)»: если «Нет потребности в режиме» ИЛИ «Объект работоспособен», которое описывается логической функцией  $y_{работ} = \bar{y}_{отказ} = \bar{y}_p \vee \bar{y}_c$ , а полином работоспособности равен:

$$\begin{aligned}
 P_{работ} &= Q_p + P_c - Q_p \cdot P_c = P_c + Q_p \cdot Q_c = \\
 &= 1 - Q_c + Q_p \cdot Q_c = 1 - P_p \cdot Q_c = 1 - P_{отказ}
 \end{aligned}$$

С одной стороны, чем меньше потребности в режиме, тем более работоспособен МрО и повышается вероятность выполнения этого режима. С другой стороны, интенсивное задействование режима приводит к уменьшению вероятности безотказной работы (ВБР) ФЭ, участвующих в выполнении этого режима.

Для того чтобы развязать данный замкнутый круг, предлагается применить следующий подход. Введем интенсивность (вероятность) задействования режима функционирования МрО. Тогда под выражением «вероятность режима равна 1» будем понимать, что-либо

в любой момент времени может потребоваться режим либо этот режим постоянно задействуется с интенсивностью 1. Если же режим постоянно задействуется, то вероятность выполнения режима зависит только от ВБР ФЭ МрО, т.к.  $Q_p = 0$  и  $P_{работ} = P_c \geq 0$ . Но если интенсивность режима (вероятность его задействования) уменьшается и стремится к 0 ( $P_p \rightarrow 0$ ), то вероятность выполнения режима также будет иметь подобную зависимость от ВБР ФЭ МрО. Однако значения вероятности выполнения режима будут сдвинуты вверх на  $Q_p$  и ее нижняя оценка будет повышаться и стремиться к 1 (т.к.  $P_{работ} = Q_p + P_c - Q_p \cdot P_c \geq Q_p = 1 - P_p$ ). Указанные соображения следует учитывать при дальнейшем исследовании реализации режимов функционирования МрО. При этом необходимо отметить, что отдельные режимы могут быть несовместными (т.е. могут выполняться поочередно) и являются основными, а ряд режимов являются дополнительными и могут осуществляться одновременно с основными режимами. Может встречаться и более сложная взаимосвязь задействования режимов. Поэтому функциональные вершины СФЦ отражают как работоспособность тех или иных ФЭ МрО, так и потребности в реализации тех или иных режимов функционирования МрО.

Пусть вероятностный полином успешной реализации режимов функционирования МрО имеет вид (1):

$$\mathfrak{R}(P_1, \dots, P_n, P_{n+1}, \dots, P_{n+m}), \quad (1)$$

где  $P_i, i = \overline{1, n}$  – вероятности безотказной работы ФЭ МрО, а  $P_{n+i}, i = \overline{1, m}$  – интенсивности задействования режимов функционирования МрО. Обозначим интенсивности задействования режимов функционирования МрО через  $\alpha_i = P_{n+i}, i = \overline{1, m}$ .

Используя введенный авторами параметрический геном структуры [17, 20] МрО  $\vec{\chi}(\alpha_1, \alpha_2, \dots, \alpha_m) = (\chi_0(\alpha_1, \alpha_2, \dots, \alpha_m), \chi_1(\alpha_1, \alpha_2, \dots, \alpha_m), \dots, \chi_n(\alpha_1, \alpha_2, \dots, \alpha_m))^T$ , представляющий собой вектор коэффициентов полинома (2) успешной реализации режимов функционирования объекта, состоящего из однородных ФЭ (т.е.  $P_1 = P_2 = \dots = P_n = P$ ),

$$\mathfrak{R}(P, \alpha_1, \dots, \alpha_m) = \chi_0(\alpha_1, \dots, \alpha_m) + \chi_1(\alpha_1, \dots, \alpha_m)P + \dots + \chi_n(\alpha_1, \dots, \alpha_m)P^n, \quad (2)$$

можно вычислить значения показателей структурно-функциональной надежности однородного и неоднородного МрО по формулам (3):

$$\begin{aligned}
 F_{\text{однор}}(\bar{\chi}(\alpha_1, \dots, \alpha_m)) &= \int_0^1 \mathfrak{R}(P, \alpha_1, \dots, \alpha_m) dP = \bar{\chi}(\alpha_1, \dots, \alpha_m) \cdot \left(1, \frac{1}{2}, \frac{1}{3}, \dots, \frac{1}{n+1}\right)^T, \\
 F_{\text{неоднор}}(\bar{\chi}(\alpha_1, \dots, \alpha_m)) &= \int_0^1 \dots \int_0^1 \mathfrak{R}(P_1, \dots, P_n, \alpha_1, \dots, \alpha_m) dP_1 dP_2 \dots dP_n = \\
 &= \bar{\chi}(\alpha_1, \dots, \alpha_m) \cdot \left(1, \frac{1}{2}, \frac{1}{2^2}, \dots, \frac{1}{2^n}\right)^T.
 \end{aligned} \tag{3}$$

Учитывая тот факт, что режимы функционирования могут быть совместными и/или несовместными, интенсивности их задействования – равноценными и/или неравноценными, а структура взаимосвязей ФЭ МрО однородной или неоднородной, следует воспользоваться подходом, предложенным в работах [17 – 20], для вычисления интегральных показателей структурно-функциональной надежности однородного и неоднородного МрО по формулам (4) – (7):

$$J_{pp} = m \cdot \int_0^{1/m} F_*(\bar{\chi}_p(\alpha)) d\alpha, \tag{4}$$

$$J_{cp} = \int_0^1 F_*(\bar{\chi}_c(\alpha)) d\alpha, \tag{5}$$

$$J_{pm} = m! \cdot \iiint_{\substack{\alpha_1 + \dots + \alpha_m \leq 1 \\ 0 \leq \alpha_i \leq 1, i=1, \dots, m}} F_*(\bar{\chi}_p(\alpha_1, \dots, \alpha_m)) d\alpha_1 d\alpha_2 \dots d\alpha_m, \tag{6}$$

$$J_{cm} = \int_0^1 \int_0^1 \dots \int_0^1 F_*(\bar{\chi}_c(\alpha_1, \dots, \alpha_m)) d\alpha_1 d\alpha_2 \dots d\alpha_m, \tag{7}$$

где показатели (4) и (5) предназначены для оценивания однородных и неоднородных объектов при несовместном и совместном задействовании равноценных по интенсивности режимов функционирования соответственно, а показатели (6) и (7) – при соответственно несовместном (раздельном) и совместном задействовании неравноценных по интенсивности режимов функционирования. В формулах (4) – (7) в качестве функции  $F_*$  могут

быть использованы  $F_{однор}$  или  $F_{неоднор}$  для соответствующих параметрических геномов  $\vec{\chi}_p(\alpha), \vec{\chi}_c(\alpha), \vec{\chi}_p(\alpha_1, \dots, \alpha_m), \vec{\chi}_c(\alpha_1, \dots, \alpha_m)$  – раздельного задействия равноценных по интенсивности режимов функционирования, совместного задействия равноценных по интенсивности режимов функционирования, раздельного задействия неравноценных по интенсивности режимов функционирования, совместного задействия неравноценных по интенсивности режимов функционирования.

**3. Математическая постановка задачи структурно-параметрического синтеза конфигураций МрО.** Предложенные в разделе 2 обобщенные показатели (4) – (7) структурно-функциональной надежности МрО, рассматриваемые в рамках указанных сценариев реализации циклограмм режимов функционирования могут быть использованы при математической постановке решаемой задачи синтеза. Следует отметить, что вычисление значений данных показателей представляет собой трудоемкий процесс. Однако в работе [21] было показано, что в самом общем виде подынтегральное выражение в формулах (4) – (7) можно представить следующим образом (8):

$$\begin{aligned}
 F_*(\vec{\chi}(\alpha_1, \dots, \alpha_m)) = & \beta_0 + \sum_{i=1}^m \beta_i \alpha_i + \sum_{i=1}^m \sum_{j=i+1}^m \beta_{ij} \alpha_i \alpha_j + \\
 & + \sum_{i=1}^m \sum_{j=i+1}^m \sum_{k=j+1}^m \beta_{ijk} \alpha_i \alpha_j \alpha_k + \dots + \beta_{12\dots m} \alpha_1 \alpha_2 \dots \alpha_m.
 \end{aligned} \tag{8}$$

Таким образом, функция  $F_*(\vec{\chi}(\alpha_1, \dots, \alpha_m))$  предстает в явном виде как выражение, зависящее от параметров  $\alpha_1, \dots, \alpha_m$ . При этом коэффициенты  $\beta_i, \dots, \beta_{ij}, \dots, \beta_{ijk}, \dots, \beta_{12\dots m}$  одночленов в выражении (8) принимают конкретные значения для рассматриваемой СФЦ при однородном (неоднородном) описании структуры объекта.

Согласно результатам, приведенным в работе [21], для вычисления показателей (4) – (7) можно воспользоваться упрощенными формулами (9) – (12).

$$J_{pp} = \frac{\beta_0}{m^0 \cdot 1} + \frac{\sum_{i=1}^m \beta_i}{m \cdot 2} + \frac{\sum_{i=1}^m \sum_{j=i+1}^m \beta_{ij}}{m^2 \cdot 3} + \dots + \frac{\beta_{12\dots m}}{m^m \cdot (m+1)}, \tag{9}$$

$$J_{cp} = \frac{\beta_0}{1} + \frac{\sum_{i=1}^m \beta_i}{2} + \frac{\sum_{i=1}^m \sum_{j=i+1}^m \beta_{ij}}{3} + \dots + \frac{\beta_{12\dots m}}{(m+1)}, \quad (10)$$

$$J_{pn} = \frac{\beta_0}{1} + \frac{\sum_{i=1}^m \beta_i}{m+1} + \frac{\sum_{i=1}^m \sum_{j=i+1}^m \beta_{ij}}{(m+1) \cdot (m+2)} + \dots + \frac{\beta_{12\dots m}}{(m+1) \cdot (m+2) \cdot \dots \cdot (m+m)}, \quad (11)$$

$$J_{cn} = \frac{\beta_0}{2^0} + \frac{\sum_{i=1}^m \beta_i}{2^1} + \frac{\sum_{i=1}^m \sum_{j=i+1}^m \beta_{ij}}{2^2} + \dots + \frac{\beta_{12\dots m}}{2^m}. \quad (12)$$

Предложенный выше подход также можно применить для определения значимостей ФЭ МрО, которые можно использовать при линеаризации рассматриваемых показателей (4) – (7). Для вычисления значимости  $i$ -го ФЭ требуется построить вероятностный полином (13), представляющий собой частную производную от коэффициента готовности (вероятности безотказной работы) объекта по коэффициенту готовности элемента [16, 21]:

$$\xi_i(P_1, \dots, P_n, \alpha_1, \dots, \alpha_m) = \frac{\partial \mathfrak{R}(P_1, \dots, P_n, \alpha_1, \dots, \alpha_m)}{\partial P_i} = \mathfrak{R}(P_1, \dots, P_n, \alpha_1, \dots, \alpha_m) \Big|_{P_i=1} - \mathfrak{R}(P_1, \dots, P_n, \alpha_1, \dots, \alpha_m) \Big|_{P_i=0}. \quad (13)$$

Тогда каждому полиному  $\xi_i(P_1, \dots, P_n, \alpha_1, \dots, \alpha_m)$  ( $\forall i = 1, \dots, n$ ) сопоставим соответствующие параметрические геномы  $\bar{\chi}^i(\alpha_1, \alpha_2, \dots, \alpha_m)$ , используя которые можно вычислять значимости ФЭ МрО по вышеприведенным формулам (9) – (12).

Учитывая концептуальное описание решаемой задачи, перейдем к ее математической постановке. Для построения обобщенной математической модели рассматриваемой задачи структурно-параметрического синтеза конфигураций МрО предлагается воспользоваться теоретико-множественным подходом [22]. Тогда в качестве основных множеств её элементов и характеристик определим следующие [23]:

$$A = \{A_i, i \in N\}, N = \{1, 2, 3, \dots, n\} - \text{множество ФЭ МрО};$$

$B = \{B_j^i, j \in D^i, D^i = \{1, 2, 3, \dots, k_i\}, i \in N\}$  – номенклатура элементной базы ФЭ, где  $B_j^i$  обозначает j-й тип А<sub>i</sub> ФЭ МрО, в которой учтена возможная кратность резервирования;

$\mathfrak{R}(P_1, \dots, P_n, \alpha_1, \alpha_2, \dots, \alpha_m)$  – вероятностный полином или вероятностная функция (ВФ) безотказной работы МрО при реализации режимов функционирования, в которой учтены мажоритарное резервирование и совместность их задействования [18,21,24];

$\bar{\chi}(\alpha_1, \dots, \alpha_m) = (\chi_0(\alpha_1, \dots, \alpha_m), \chi_1(\alpha_1, \dots, \alpha_m), \dots, \chi_n(\alpha_1, \dots, \alpha_m))^T$  – параметрический геном структуры МрО при реализации режимов функционирования;

$\alpha_l, l \in \{1, \dots, m\}$  – интенсивности востребования (задействования) режимов функционирования МрО;

$c_{ij}, i \in N, j \in \{1, 2, \dots, k_i\}$  – коэффициенты эффективности потребления ресурсов ФЭ МрО;

$r_{ij}, i \in N, j \in \{1, \dots, m_i\}$  – вероятность безотказной работы ФЭ МрО.

Через  $X = \parallel x_{ij} \parallel$  будем обозначать вариант конфигурации проектируемого МрО. Здесь  $x_{ij} = 1$  в случае использования элемента  $B_j^i$  типа в качестве А<sub>i</sub> ФЭ, и  $x_{ij} = 0$  в противном случае [25].

Далее будем рассматривать два частных случая:

– *детерминированный*: совместность задействования режимов функционирования учтена при построении ВФ, а интенсивности задействования режимов функционирования МрО заданы [26];

– *недетерминированный*: совместность и интенсивности задействования режимов неизвестны [18 – 21].

Первый частный случай отражает тот факт, что на этапе проектирования многое известно о задействовании режимов функционирования МрО. Тогда в качестве показателя структурно-функциональной надежности МрО при реализации заданных режимов функционирования МрО будем использовать целевую функцию:

$$P_o(X) = \mathfrak{R}\left(\sum_{j=1}^{k_1} p_{1j} \cdot x_{1j}, \sum_{j=1}^{k_2} p_{2j} \cdot x_{2j}, \dots, \sum_{j=1}^{k_n} p_{nj} \cdot x_{nj}, \alpha_1, \alpha_2, \dots, \alpha_m\right).$$

Рассмотрение второго случая связано с необходимостью исследования ситуации, когда на этапе проектирования исходных



данных и информации о задействовании режимов функционирования МрО недостаточно. При этом для второго случая предлагается провести исследования следующих крайних частных вариантов: в первом варианте все режимы могут быть задействованы раздельно, во втором варианте – совместно, с одинаковой или различной интенсивностью [18 – 21].

Следует отметить, что раздельное или совместное задействование всех режимов функционирования учитывается при построении ВФ  $\mathfrak{R}_{p(c)}(P_1, \dots, P_n, \alpha_1, \alpha_2, \dots, \alpha_m)$  [16]. Тогда в качестве целевых функций структурно-функциональной надежности МрО при реализации режимов функционирования будем использовать (см. формулы (4), (5)) либо:

$$P_{pp}(X) = m \cdot \int_0^{1/m} \mathfrak{R}_{pp} \left( \sum_{j=1}^{k_1} p_{1j} \cdot x_{1j}, \sum_{j=1}^{k_2} p_{2j} \cdot x_{2j}, \dots, \sum_{j=1}^{k_n} p_{nj} \cdot x_{nj}, \alpha \right) d\alpha,$$

если все режимы задействуются раздельно с одинаковой интенсивностью (равноценные режимы), либо:

$$P_{cp}(X) = \int_0^1 \mathfrak{R}_{cp} \left( \sum_{j=1}^{k_1} p_{1j} \cdot x_{1j}, \sum_{j=1}^{k_2} p_{2j} \cdot x_{2j}, \dots, \sum_{j=1}^{k_n} p_{nj} \cdot x_{nj}, \alpha \right) d\alpha,$$

при совместном задействовании всех режимов также с одинаковой интенсивностью. При различной интенсивности задействования режимов (неравноценные режимы) в качестве целевых функций структурно-функциональной надежности МрО при реализации режимов функционирования [26] будем использовать (формулы (6), (7)), либо формулу:

$$P_{pn}(X) = m! \cdot \iiint_{\substack{\alpha_1 + \dots + \alpha_m \leq 1 \\ 0 \leq \alpha_i \leq 1, i=1, \dots, m}} \mathfrak{R}_{pn} \left( \sum_{j=1}^{k_1} p_{1j} \cdot x_{1j}, \sum_{j=1}^{k_2} p_{2j} \cdot x_{2j}, \dots, \sum_{j=1}^{k_n} p_{nj} \cdot x_{nj}, \alpha_1, \dots, \alpha_m \right) d\alpha_1 \dots d\alpha_m,$$

при раздельном задействовании всех режимов, либо формулу следующего вида:

$$P_{cn}(X) = \int_0^1 \int_0^1 \dots \int_0^1 \mathfrak{R}_{cn} \left( \sum_{j=1}^{k_1} p_{1j} \cdot x_{1j}, \sum_{j=1}^{k_2} p_{2j} \cdot x_{2j}, \dots, \sum_{j=1}^{k_n} p_{nj} \cdot x_{nj}, \alpha_1, \dots, \alpha_m \right) d\alpha_1 \dots d\alpha_m,$$

при совместном их задействовании.

Предложенные целевые функции для второго частного случая  $(P_{pp}(X), P_{cp}(X), P_{pn}(X), P_{cn}(X))$  позволяют оценить крайние варианты задействования режимов, т.е. дать в некотором смысле пессимистические и оптимистические оценки надежности [27 – 28].

В качестве целевых функций учета ресурсных требований к варианту конфигурации объекта используем формулу следующего

$$\text{вида } C(X) = \sum_{i=1}^n \sum_{j=1}^{k_i} c_{ij} \cdot x_{ij} .$$

Важно отметить, что в случае широкой номенклатуры элементной базы для решения рассматриваемой задачи требуется

ввести следующие ограничения:  $\sum_{j=1}^{k_i} x_{ij} \leq 1, \forall i \in N$ , содержание которых

состоят в том, что в МрО в качестве  $A_i$  ФЭ используется какой-то элемент  $B_j^i$  типа из его номенклатуры.

В противоположном случае, то есть для узкой номенклатуры,

указанное неравенство  $\sum_{j=1}^{k_i} x_{ij} \leq 1, \forall i \in N$  будет обозначать, что

максимальная кратность резервирования  $A_i$  ФЭ МрО не более  $k_i$  и  $x_{ij} = 1$  при  $j$  - кратном дублировании  $A_i$  ФЭ.

При этом:

$$p_{i1} = p_i, p_{i2} = 1 - (1 - p_i)^2, \dots, p_{ik_i} = 1 - (1 - p_i)^{k_i}, \forall i \in N,$$

$$g_{i1} = g_i, g_{i2} = 2g_i, \dots, g_{ik_i} = k_i g_i, \forall i \in N, \text{ и}$$

$$c_{i1} = c_i, c_{i2} = 2c_i, \dots, c_{im_i} = m_i c_i, \forall i \in N.$$

Таким образом, получаем область  $\Delta$  допустимых вариантов конфигурации МрО, задаваемую неявно с помощью вышеуказанных ограничений.

Учитывая всё вышесказанное, можно утверждать, что задача структурно-параметрического синтеза конфигураций МрО сводится к решению следующих многокритериальных задач выбора [29, 30].

Для первого частного случая:

$$\min_{X \in \Delta} C(X), \max_{X \in \Delta} P_0(X) . \quad (14)$$

Для второго частного случая:

$$\min_{X \in \Delta} C(X), \max_{X \in \Delta} P_{pp}(X), \max_{X \in \Delta} P_{cp}(X), \max_{X \in \Delta} P_{pn}(X), \max_{X \in \Delta} P_{cn}(X). \quad (15)$$

Иначе говоря, требуется найти недоминируемые (паретовские) варианты конфигураций  $\text{MrO } \Delta^{nd} \subseteq \Delta$ , удовлетворяющие следующим критериям оптимальности: при минимальном ресурсопотреблении  $\text{MrO}$  обеспечить максимально возможные значения показателей структурно-функциональной надежности  $\text{MrO}$  реализации режимов функционирования для детерминированных условий их использования [31 – 33] (частный случай 1, задача (14)), для неопределенных условий задействования режимов (частный случай 2, задача (15)).

Следует отметить, что одна из главных особенностей задач многокритериального выбора (в частности задач (14), (15)) состоит в том, что данные задачи не являются корректными в рамках аксиоматики, принятой в классической теории оптимизации и принятия решения [25, 29, 31–34]. Действительно, на основе различных критериев оптимизации получаются различные решения, не совпадающие в общем случае друг с другом, что приводит к появлению в задачах принятия решений специфического вида неопределенности – *критериальной неопределенности*. Для снятия указанной неопределенности необходимо использовать методы многокритериального выбора, основу которых составляет доопределение (уточнение) задачи путем привлечения дополнительной качественной и количественной информации от лица, принимающего решение (ЛПР). Как правило, эта информация касается свойств критериальных функций, свойств множества альтернатив и достигается введением некоторых аксиом (принципов оптимальности) о том, что следует понимать под оптимальным (рациональным, недоминируемым) в целом решением в этой неопределенной ситуации.

#### 4. Комбинированный метод решения поставленных задач.

Трудности решения приведенных многокритериальных задач выбора на дискретном допустимом множестве вариантов конфигураций  $\text{MrO}$  вызваны наличием как критериальной неопределенности, так и нелинейностью целевых функций  $P_o(X), P_{pp}(X), P_{cp}(X), P_{pn}(X), P_{cn}(X)$ .

В работе [19] проведен анализ задачи (14), и в качестве способа преодоления критериальной неопределенности был обоснованно предложен интервальный лексикографический метод решения многокритериальной задачи. При этом для случая, когда вероятностная функция

$P_o(X) = \Re(\sum_{j=1}^{k_1} P_{1j} \cdot x_{1j}, \sum_{j=1}^{k_2} P_{2j} \cdot x_{2j}, \dots, \sum_{j=1}^{k_n} P_{nj} \cdot x_{nj}, \alpha_1, \alpha_2, \dots, \alpha_m)$  безотказной

работы МрО при реализации режимов функционирования описывает монотонную структуру МрО, её можно заменить линейным аналогом следующего вида  $\sum_{i=1}^n \sum_{j=1}^{k_i} \mu_{ij} \cdot x_{ij}$ , которое интерпретируется как

суммарное приращение ВБР МрО в результате использования конкретно взятых элементов при проектировании МрО. Здесь величины  $\mu_{ij} = \tilde{\xi}_i \cdot p_{ij}, i \in N, j \in \{1, 2, \dots, k_i\}$  характеризуют вклад в соответствующий обобщенный показатель структурно-функциональной надежности при использовании в проекте А<sub>1</sub>ФЭ МрО В<sub>j</sub><sup>i</sup> – го типа,  $\tilde{\xi}_i, i \in N$  – структурная значимость ФЭ МрО при реализации режимов функционирования, вычисляемая по формуле  $\tilde{\xi}_i = \xi_i \left( \frac{1}{2}, \dots, \frac{1}{2}, \alpha_1, \dots, \alpha_m \right) = \bar{\chi}^i(\alpha_1, \alpha_2, \dots, \alpha_m) \cdot \left( 1, \frac{1}{2}, \frac{1}{2}, \dots, \frac{1}{2} \right)^T, i \in N$ .

Основным этапом решения рассматриваемых задач является нахождение эффективных (удовлетворяющих заявленным требованиям и ограничениям) вариантов разрабатываемого МрО, которые распределены равномерно в области недоминируемых альтернатив (Парето). Для реализации данного этапа необходимо найти  $P_i^{\min} = \min_{j \in \{1, 2, \dots, k_i\}} P_{ij}, P_i^{\max} = \max_{j \in \{1, 2, \dots, k_i\}} P_{ij}, \forall i \in N$  и соответствующие

им варианты конфигураций МрО  $X^{\min} = \left\| x_{ij}^{\min} \right\|, X^{\max} = \left\| x_{ij}^{\max} \right\|$ . Для данных вариантов можно вычислить соответственно минимальное и максимальное значение вероятностной функции

$$P_o(X) = \Re\left(\sum_{j=1}^{k_1} P_{1j} \cdot x_{1j}, \sum_{j=1}^{k_2} P_{2j} \cdot x_{2j}, \dots, \sum_{j=1}^{k_n} P_{nj} \cdot x_{nj}, \alpha_1, \alpha_2, \dots, \alpha_m\right), \text{ а именно}$$

$$P_{\min} = P_o(X^{\min}), P_{\max} = P_o(X^{\max}).$$

Используя полученные решения (альтернативы) конфигураций МрО, вычислим соответствующие им значения показателей ресурсопотребления  $C^1 = C(X^{\min}), C^2 = C(X^{\max})$ . Так как окончательное решение по выбору варианта конфигураций МрО за ЛПП, то им может быть указано необходимое количество недоминируемых альтернатив, которые должны быть представлены для последующего анализа [33]. Для того чтобы из всего множества недоминируемых альтернатив выделить заданное количество  $k_{\text{зад}}$

эффективных решений, равномерно расположенных в области Парето, предлагается применить следующий подход, основанный на методе уступок.

Вычисляем уступки  $\Delta C$  по целевому показателю ресурсопотребления. Так как данный показатель в решаемой задаче требуется минимизировать, то находим его минимальное значение и соответствующую уступку  $C_{\min} = \min\{C^1, C^2\}, \Delta C = \frac{|C^2 - C^1|}{k_{\text{зад}} - 1}$ .

Тогда остается решить серию задач линейного булева программирования следующего вида:

$$\max_{X \in \Delta_l} \sum_{i=1}^n \sum_{j=1}^{k_i} \mu_{ij} \cdot x_{ij}, \quad (16)$$

$$\sum_{j=1}^{k_i} x_{ij} \leq 1, \forall i \in N, \quad (17)$$

$$C(X) = \sum_{i=1}^n \sum_{j=1}^{k_i} c_{ij} \cdot x_{ij} \leq C_{\min} + l \cdot \Delta C, \quad (18)$$

$$x_{ij} \in \{0,1\}, \forall i \in N, j \in \{1, \dots, k_i\} \quad (19)$$

При этом  $l = 1, \dots, k_{\text{зад}} - 1$ . Здесь  $\Delta_l$  – множество допустимых решений для заданной уступки  $l \cdot \Delta C$  по целевой функции

$$\text{ресурсопотребления } C(X) = \sum_{i=1}^n \sum_{j=1}^{k_i} c_{ij} \cdot x_{ij}.$$

Данный прием предлагается также использовать для решения задачи (15) при реализации режимов функционирования МрО. Однако, кроме одного критерия  $\max_{X \in \Delta} P_o(X)$  структурно-функциональной надежности МрО при реализации режимов функционирования, следует учитывать следующие четыре критерия оптимальности  $\max_{X \in \Delta} P_{pp}(X), \max_{X \in \Delta} P_{cp}(X), \max_{X \in \Delta} P_{pn}(X), \max_{X \in \Delta} P_{cn}(X)$ . При этом для вычисления структурной значимости ФЭ МрО  $\tilde{\xi}_i^{pp}, \tilde{\xi}_i^{cp}, \tilde{\xi}_i^{pn}, \tilde{\xi}_i^{cn}$  при реализации режимов функционирования в случае отдельного и совместного задействования равноценных или неравноценных

режимов функционирования [21] следует использовать соответственно формулы (9), (10), (11), (12). Тогда при линеаризации целевых функций  $P_{pp}(X), P_{cp}(X), P_{pn}(X), P_{cn}(X)$  целесообразно применить соответственно следующие получившиеся линеаризованные целевые функции  $\sum_{i=1}^n \sum_{j=1}^{k_i} \mu_{ij}^{pp} \cdot x_{ij}, \sum_{i=1}^n \sum_{j=1}^{k_i} \mu_{ij}^{cp} \cdot x_{ij}, \sum_{i=1}^n \sum_{j=1}^{k_i} \mu_{ij}^{pn} \cdot x_{ij}, \sum_{i=1}^n \sum_{j=1}^{k_i} \mu_{ij}^{cn} \cdot x_{ij}$ . Причем вклады в обобщенный показатель структурно-функциональной надежности  $MrO$  вычисляются следующим образом:

$$\mu_{ij}^{pp} = \tilde{\xi}_i^{pp} \cdot p_{ij}, \mu_{ij}^{cp} = \tilde{\xi}_i^{cp} \cdot p_{ij}, \mu_{ij}^{pn} = \tilde{\xi}_i^{pn} \cdot p_{ij}, \mu_{ij}^{cn} = \tilde{\xi}_i^{cn} \cdot p_{ij}, i \in N, j \in \{1, 2, \dots, k_i\}.$$

Для преодоления критериальной неопределенности, вызванной использованием критериев  $\max_{X \in \Delta} P_{pp}(X), \max_{X \in \Delta} P_{cp}(X), \max_{X \in \Delta} P_{pn}(X), \max_{X \in \Delta} P_{cn}(X)$ , предлагается «доопределить» решаемую задачу. Для этого целесообразно применить операторное решающее правило [34]: «оптимальное решение минимизирует общую верхнюю грань относительных отклонений от оптимальных решений по частным показателям». Необходимость применения данного операторного правила возникает по нескольким причинам. Во-первых, при выборе варианта конфигурации  $MrO$  используемые целевые функции  $P_{pp}(X), P_{cp}(X), P_{pn}(X), P_{cn}(X)$  имеют одинаковый приоритет. Во-вторых, так как  $MrO$  монотонен, то значимости ФЭ принимают неотрицательные значения ( $\tilde{\xi}_i^{pp} \geq 0, \tilde{\xi}_i^{cp} \geq 0, \tilde{\xi}_i^{pn} \geq 0, \tilde{\xi}_i^{cn} \geq 0, i \in N$ ). В этом случае в области  $\Delta$  допустимых вариантов конфигураций  $MrO$  нетрудно найти наибольшие значения указанных целевых функций.

Действительно,

$$P_{pp}^{\max} = \sum_{i=1}^n \tilde{\xi}_i^{pp} \cdot \max_{j \in \{1, 2, \dots, k_i\}} p_{ij}, P_{cp}^{\max} = \sum_{i=1}^n \tilde{\xi}_i^{cp} \cdot \max_{j \in \{1, 2, \dots, k_i\}} p_{ij},$$

$$P_{pn}^{\max} = \sum_{i=1}^n \tilde{\xi}_i^{pn} \cdot \max_{j \in \{1, 2, \dots, k_i\}} p_{ij}, P_{cn}^{\max} = \sum_{i=1}^n \tilde{\xi}_i^{cn} \cdot \max_{j \in \{1, 2, \dots, k_i\}} p_{ij}.$$

Получаем, что основной этап при решении задачи (15) связан непосредственно с решением задач линейного булева программирования вида (20)-(27). Суть данного этапа решения исследуемой задачи многокритериального выбора заключается в нахождении эффективного решения из области  $\Delta$ , доставляющего наименьшую общую верхнюю грань относительных отклонений от оптимальных решений по частным показателям.

$$w \rightarrow \min_{\Delta_i}, \quad (20)$$

$$\sum_{i=1}^n \sum_{j=1}^{k_i} \mu_{ij}^{pp} \cdot x_{ij} \geq (1-w) \cdot P_{pp}^{\max}, \quad (21)$$

$$\sum_{i=1}^n \sum_{j=1}^{k_i} \mu_{ij}^{cp} \cdot x_{ij} \geq (1-w) \cdot P_{cp}^{\max}, \quad (22)$$

$$\sum_{i=1}^n \sum_{j=1}^{k_i} \mu_{ij}^{pn} \cdot x_{ij} \geq (1-w) \cdot P_{pn}^{\max}, \quad (23)$$

$$\sum_{i=1}^n \sum_{j=1}^{k_i} \mu_{ij}^{cn} \cdot x_{ij} \geq (1-w) \cdot P_{cn}^{\max}, \quad (24)$$

$$\sum_{j=1}^{k_i} x_{ij} \leq 1, \forall i \in N, \quad (25)$$

$$C(X) = \sum_{i=1}^n \sum_{j=1}^{k_i} c_{ij} \cdot x_{ij} \leq C_{\min} + l \cdot \Delta C, \quad (26)$$

$$x_{ij} \in \{0, 1\}, \forall i \in N, j \in \{1, \dots, k_i\}. \quad (27)$$

Для детального анализа полученных конфигураций МрО [29] вводится обобщенное описание количественных показателей структурно-функциональной надежности МрО в рамках рассматриваемых сценариев реализации режимов функционирования в виде нечеткого трапециевидного числа с параметрами  $Z = (z_1, z_2, z_3, z_4)$ , функция принадлежности которого задается следующим образом [35]:

$$\mu_Z(x) = \begin{cases} \frac{x - z_1}{z_2 - z_1}, & \text{если } z_1 \leq x \leq z_2 \\ 1, & \text{если } z_2 \leq x \leq z_3 \\ \frac{z_4 - x}{z_4 - z_3}, & \text{если } z_3 \leq x \leq z_4 \\ 0, & \text{в остальных случаях} \end{cases}.$$

Для нахождения параметров нечеткого числа  $Z = (z_1, z_2, z_3, z_4)$  будем использовать полученные значения целевых функций  $P_o(X), P_{pp}(X), P_{cp}(X), P_{pm}(X), P_{cn}(X)$  – вероятностей безотказной работы МрО при выполнении заданных сценариев реализации режимов функционирования. В качестве параметра  $z_1$  будет служить нижняя оценка обобщенного показателя структурно-функциональной надежности МрО (пессимистическая оценка), которая вычисляется при условии совместного задействования равноценных по интенсивности режимов функционирования на всем рассматриваемом интервале времени. Два других параметра  $z_2, z_3$  являются соответственно минимальным и максимальным значениями среди показателей структурно-функциональной надежности при задействовании несовместных равноценных и неравноценных режимов. Четвертым параметром  $z_4$  будет служить значение показателя структурно-функциональной надежности объекта при несовместном задействовании равноценных по интенсивности режимов функционирования (оптимистический вариант).

В качестве интегральной оценки показателя структурно-функциональной надежности [27, 31, 32, 36, 37] варианта конфигурации МрО целесообразно принять центр тяжести (центроид, показатель деффазификации) полученного трапециевидного числа по формуле (28):

$$C_{\text{тяж}} = \frac{(z_3 - z_1)^2 + (z_4 - z_1)(z_4 - z_3) - \frac{1}{3}(z_2 - z_1)^2 - \frac{2}{3}(z_4 - z_3)^2}{z_3 - z_2 + z_4 - z_1} + z_1, \quad (28)$$

где  $z_1, z_2, z_3, z_4$  – описанные выше параметры трапеции.

Предложенный комбинированный метод решения рассматриваемой задачи и интегральные оценки обобщенного



показателя структурно-функциональной надежности конфигураций МрО проиллюстрируем на примере решения задачи многокритериального структурно-параметрического синтеза конфигураций СУД МКА ДЗЗ.

**5. Расчетный пример решения задачи структурно-параметрического синтеза конфигураций системы управления движением малого космического аппарата.** Рассмотрим СУД МКА ДЗЗ «Аист-2Д». В качестве датчиков первичной информации СУД МКА «Аист-2Д» [38, 39] привлекаются: одноосные измерители угловой скорости (ОИУС), 4 шт.; оптические солнечные датчики (ОСД), 2 шт.; звездные датчики (ЗД), 2 шт.; приборы ориентации по Земле (ПОЗ), 2 шт. Пусть оси ОИУС имеют кубическую конфигурацию («Куб»), когда три измерителя угловой скорости сонаправлены с осями МКА, а четвертый – по диагонали куба [10]. Проведем исследование СУД МКА ДЗЗ с учетом следующих режимов [38]: сброса кинетического момента (СКМ); одноосной солнечной ориентации (ОСО); трёхосной ориентации в орбитальной системе координат (ОСК); целевой режим ориентации МКА (ЦО), предназначенный для съёмки заданной области (объекта наблюдения). Схема функциональной целостности ФЭ СУД МКА при выполнении указанных выше режимов ориентации представлена на рисунке 2.

Основные функциональные вершины СФЦ отражают: 1, 2, 3 и 4 – работоспособность ОИУС<sub>1</sub>, ОИУС<sub>2</sub>, ОИУС<sub>3</sub> и ОИУС<sub>4</sub> соответственно, 5 – работоспособность ОСД<sub>1</sub>, 6 – работоспособность ОСД<sub>2</sub>, 7 - работоспособность ПОЗ<sub>1</sub>, 8 – работоспособность ПОЗ<sub>2</sub>, 9 – работоспособность ЗД<sub>1</sub>, 10 – работоспособность ЗД<sub>2</sub>, 11 – потребность в режиме СКМ, 12 – потребность в режиме ОСО, 13 – потребность в режиме ОСК, 14 – потребность в режиме ЦО. Вершины 15–34 являются фиктивными и описывают реальные логические взаимосвязи элементов СУД МКА.

Используя программный комплекс логико – вероятностного моделирования «Арбитр» [16], получим для СФЦ СУД МКА два вероятностных полинома успешного его функционирования  $\mathfrak{R}_c(P_1, \dots, P_{10}, P_{11}, \dots, P_{14}), \mathfrak{R}_p(P_1, \dots, P_{10}, P_{11}, \dots, P_{14})$ , где  $\mathfrak{R}_c(P_1, \dots, P_{10}, P_{11}, \dots, P_{14})$  – вероятностная функция проведения успешной ориентации МКА СУД для режимов, не являющихся группой несовместных событий (ГНС);  $\mathfrak{R}_p(P_1, \dots, P_{10}, P_{11}, \dots, P_{14})$  – вероятностная функция проведения успешной ориентации МКА СУД для режимов, представляющих ГНС;  $P_i, i = \overline{1, 10}$  – вероятности безотказной работы

ФЭ СУДН а  $P_{10+i}, i = \overline{1,4}$  – интенсивности (вероятности) реализации режимов ориентации СУД.




Рис. 2. СФЦ датчиков СУД для конфигурации «Куб»

Номенклатура ФЭ, используемая в решаемой задаче, и исходные данные по ним приведены в таблицах 1 – 3.

Таблица 1. Исходные данные по значениям показателей надежности элементов

| ФЭ | 1     | 2     | 3     | 4     | 5     | 6     |
|----|-------|-------|-------|-------|-------|-------|
| 1  | 0,955 | 0,884 | 0,963 | -     | -     | -     |
| 2  | 0,955 | 0,884 | 0,963 | -     | -     | -     |
| 3  | 0,973 | 0,811 | 0,915 | 0,915 | 0,915 | 0,969 |
| 4  | 0,973 | 0,811 | 0,915 | 0,915 | 0,915 | 0,969 |
| 5  | 0,973 | 0,811 | 0,915 | 0,915 | 0,915 | 0,969 |
| 6  | 0,973 | 0,811 | 0,915 | 0,915 | 0,915 | 0,969 |
| 7  | 0,957 | 0,971 | 0,921 | -     | -     | -     |
| 8  | 0,957 | 0,971 | 0,921 | -     | -     | -     |
| 9  | 0,95  | 0,949 | 0,985 | 0,998 | -     | -     |
| 10 | 0,993 | 0,993 | 0,889 | 0,999 | -     | -     |

Таблица 2. Исходные данные по энергопотреблению элементов

| ФЭ | 1    | 2   | 3  | 4   | 5  | 6  |
|----|------|-----|----|-----|----|----|
| 1  | 11   | 8   | 20 | -   | -  | -  |
| 2  | 11   | 8   | 20 | -   | -  | -  |
| 3  | 15   | 15  | 15 | 18  | 11 | 14 |
| 4  | 15   | 15  | 15 | 18  | 11 | 14 |
| 5  | 15   | 15  | 15 | 18  | 11 | 14 |
| 6  | 15   | 15  | 15 | 18  | 11 | 14 |
| 7  | 4,5  | 0,5 | 6  | -   | -  | -  |
| 8  | 4,5  | 0,5 | 6  | -   | -  | -  |
| 9  | 16,5 | 25  | 20 | 75  | -  | -  |
| 10 | 52   | 25  | 30 | 130 | -  | -  |

Таблица 3. Исходные данные по весовым характеристикам элементов

| ФЭ | 1   | 2   | 3   | 4   | 5 | 6   |
|----|-----|-----|-----|-----|---|-----|
| 1  | 10  | 1,8 | 6   | -   | - | -   |
| 2  | 10  | 1,8 | 6   | -   | - | -   |
| 3  | 3,3 | 4,3 | 4,3 | 4,8 | 2 | 3,2 |
| 4  | 3,3 | 4,3 | 4,3 | 4,8 | 2 | 3,2 |
| 5  | 3,3 | 4,3 | 4,3 | 4,8 | 2 | 3,2 |
| 6  | 3,3 | 4,3 | 4,3 | 4,8 | 2 | 3,2 |
| 7  | 1,6 | 3,5 | 0,7 | -   | - | -   |
| 8  | 1,6 | 3,5 | 0,7 | -   | - | -   |
| 9  | 6   | 6   | 9   | 55  | - | -   |
| 10 | 12  | 8,8 | 10  | 9,5 | - | -   |

Результаты многокритериального структурно-параметрического синтеза эффективных конфигураций СУД МКА (рисунок 2) приведены в таблице 4.

Кроме того, в таблице 5 представлены значения обобщенного показателя структурно-функциональной надежности для каждого из полученных недоминируемых вариантов конфигураций исследуемой системы при реализации всех режимов ориентации, максимально задействованных на всем рассматриваемом интервале времени совместно (пессимистический вариант) – нижняя оценка показателя структурно-функциональной надежности, а также оценки при реализации отдельно взятых режимов.

Таблица 4. Эффективные (паретовские) варианты конфигураций СУД МКА

| Вариант | ФЭ |   |   |   |   |   |   |   |   |    | Масса | Энергопотребление | ГНС<br>равн | ГНС<br>неравн | Без ГНС<br>равн | Без ГНС<br>неравн |
|---------|----|---|---|---|---|---|---|---|---|----|-------|-------------------|-------------|---------------|-----------------|-------------------|
|         | 1  | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 |       |                   |             |               |                 |                   |
| 1       | 2  | 2 | - | 5 | - | - | 1 | 2 | - | -  | 10,7  | 32                | 0,399482    | 0,399482      | 0,129626        | 0,154138          |
| 2       | 1  | - | 5 | 5 | - | - | 2 | 2 | - | -  | 21    | 34                | 0,438437    | 0,438437      | 0,142896        | 0,170175          |
| 3       | 1  | 2 | - | 6 | - | - | 2 | 2 | - | -  | 22    | 34                | 0,443062    | 0,443062      | 0,144822        | 0,17264           |
| 4       | 2  | 2 | 5 | 1 | - | - | 3 | 3 | - | -  | 10,3  | 54                | 0,482865    | 0,482865      | 0,16056         | 0,192514          |
| 5       | 2  | 2 | 6 | 1 | 5 | 5 | 2 | 2 | - | -  | 21,1  | 68                | 0,735073    | 0,735073      | 0,365407        | 0,454431          |
| 6       | 1  | 2 | 5 | 1 | 5 | 5 | 2 | 2 | - | -  | 28,1  | 68                | 0,738146    | 0,738146      | 0,366828        | 0,456224          |
| 7       | 2  | 2 | 6 | 6 | 5 | 5 | 3 | 3 | 1 | -  | 21,4  | 94,5              | 0,966004    | 0,966004      | 0,937706        | 0,943726          |
| 8       | 3  | 2 | 1 | 1 | 5 | 5 | 2 | 2 | 1 | -  | 31,4  | 97,5              | 0,978241    | 0,978241      | 0,953693        | 0,959284          |
| 9       | 3  | 1 | 6 | 6 | 6 | 5 | 2 | 2 | 1 | -  | 40,6  | 101,5             | 0,98209     | 0,98209       | 0,960545        | 0,965582          |
| 10      | 2  | 2 | 1 | 1 | 5 | 5 | 1 | 1 | 1 | 2  | 32,2  | 118,5             | 0,980351    | 0,980351      | 0,971853        | 0,973115          |
| 11      | 1  | 1 | 1 | 1 | 1 | 6 | 2 | 2 | 3 | -  | 49,1  | 102               | 0,991114    | 0,991114      | 0,983308        | 0,984998          |
| 12      | 3  | 2 | 1 | 1 | 1 | 1 | 2 | 2 | 1 | 2  | 42,8  | 130,5             | 0,992195    | 0,992195      | 0,988229        | 0,988814          |
| 13      | 3  | 3 | 6 | 1 | 6 | 6 | 1 | 1 | 1 | 2  | 42,9  | 147,5             | 0,995271    | 0,995271      | 0,992662        | 0,993115          |
| 14      | 3  | 1 | 6 | 1 | 6 | 6 | 2 | 2 | 3 | 2  | 53,7  | 134               | 0,995215    | 0,995215      | 0,992865        | 0,993234          |
| 15      | 3  | 1 | 1 | 1 | 1 | 6 | 2 | 2 | 3 | 2  | 53,9  | 136               | 0,995441    | 0,995441      | 0,993259        | 0,993598          |
| 16      | 3  | 3 | 1 | 1 | 1 | 1 | 2 | 2 | 3 | 2  | 50    | 146               | 0,995829    | 0,995829      | 0,993884        | 0,994186          |
| 17      | 3  | 3 | 1 | 1 | 1 | 1 | 2 | 2 | 3 | 4  | 50,7  | 251               | 0,995852    | 0,995852      | 0,993939        | 0,994233          |
| 18      | 3  | 3 | 1 | 1 | 1 | 1 | 2 | 2 | 4 | 2  | 96    | 201               | 0,995852    | 0,995852      | 0,99394         | 0,994234          |
| 19      | 3  | 3 | 1 | 1 | 1 | 1 | 2 | 2 | 4 | 4  | 96,7  | 306               | 0,995855    | 0,995855      | 0,993947        | 0,99424           |

Таблица 5. Оценки структурно-функциональной надежности недоминируемых вариантов конфигураций СУД МКА

| Вариант | Нижняя оценка | 1 режим  | 2 режим  | 3 режим  | 4 режим  |
|---------|---------------|----------|----------|----------|----------|
| 1       | 0             | 0,715032 | 0        | 0,845988 | 0        |
| 2       | 0             | 0,79955  | 0        | 0,927305 | 0        |
| 3       | 0             | 0,818049 | 0        | 0,927305 | 0        |
| 4       | 0             | 0,962251 | 0        | 0,904889 | 0        |
| 5       | 0             | 0,974166 | 0,986268 | 0,954965 | 0        |
| 6       | 0             | 0,976325 | 0,986676 | 0,962691 | 0        |
| 7       | 0,912201803   | 0,973275 | 0,985304 | 0,909848 | 0,931271 |
| 8       | 0,930464106   | 0,987394 | 0,988173 | 0,966013 | 0,944267 |
| 9       | 0,939740964   | 0,992649 | 0,994    | 0,968223 | 0,946369 |
| 10      | 0,965876331   | 0,975049 | 0,986351 | 0,94289  | 0,980738 |
| 11      | 0,976200391   | 0,992731 | 0,996125 | 0,967956 | 0,98075  |
| 12      | 0,985499574   | 0,987394 | 0,994639 | 0,966013 | 0,993618 |
| 13      | 0,990643636   | 0,993781 | 0,996304 | 0,955123 | 0,996245 |
| 14      | 0,991175436   | 0,993068 | 0,996103 | 0,96836  | 0,996211 |
| 15      | 0,991703245   | 0,993474 | 0,996326 | 0,968498 | 0,996348 |
| 16      | 0,992494307   | 0,994159 | 0,996636 | 0,968778 | 0,996628 |
| 17      | 0,992583641   | 0,994159 | 0,996636 | 0,968778 | 0,996718 |
| 18      | 0,992584634   | 0,994159 | 0,996636 | 0,968778 | 0,996719 |
| 19      | 0,992596545   | 0,994159 | 0,996636 | 0,968778 | 0,996731 |

В таблице 6 представлены результаты вычисления нечеткого трапециевидного числа и центры тяжести полученных трапеций, однозначно характеризующих итоговый показатель структурно-функциональной надежности каждого из вариантов конфигураций СУД МКА.

Таблица 6. Показатели структурно-функциональной надежности вариантов конфигураций в виде нечеткого трапециевидного числа

| Вариант | Трапециевидная интегральная оценка |          |          |          | Центр тяжести |
|---------|------------------------------------|----------|----------|----------|---------------|
|         | $z_1$                              | $z_2$    | $z_3$    | $z_4$    |               |
| 1       | 0                                  | 0,129626 | 0,154138 | 0,399482 | 0,17934       |
| 2       | 0                                  | 0,142896 | 0,170175 | 0,438437 | 0,1971        |
| 3       | 0                                  | 0,144822 | 0,17264  | 0,443062 | 0,199361      |
| 4       | 0                                  | 0,16056  | 0,192514 | 0,482865 | 0,218458      |
| 5       | 0                                  | 0,365407 | 0,454431 | 0,735073 | 0,38319       |
| 6       | 0                                  | 0,366828 | 0,456224 | 0,738146 | 0,384753      |
| 7       | 0,912202                           | 0,937706 | 0,943726 | 0,966004 | 0,939695      |
| 8       | 0,930464                           | 0,953693 | 0,959284 | 0,978241 | 0,955139      |
| 9       | 0,939741                           | 0,960545 | 0,965582 | 0,98209  | 0,961708      |
| 10      | 0,965876                           | 0,971853 | 0,973115 | 0,980351 | 0,972887      |
| 11      | 0,9762                             | 0,983308 | 0,984998 | 0,991114 | 0,983839      |
| 12      | 0,9855                             | 0,988229 | 0,988814 | 0,992195 | 0,98873       |
| 13      | 0,990644                           | 0,992662 | 0,993115 | 0,995271 | 0,992932      |
| 14      | 0,991175                           | 0,992865 | 0,993234 | 0,995215 | 0,993143      |
| 15      | 0,991703                           | 0,993259 | 0,993598 | 0,995441 | 0,99352       |
| 16      | 0,992494                           | 0,993884 | 0,994186 | 0,995829 | 0,994116      |
| 17      | 0,992584                           | 0,993939 | 0,994233 | 0,995852 | 0,99417       |
| 18      | 0,992585                           | 0,99394  | 0,994234 | 0,995852 | 0,994171      |
| 19      | 0,992597                           | 0,993947 | 0,99424  | 0,995855 | 0,994178      |

Поясним, каким образом результаты, полученные при использовании предложенного метода, позволяют, по сравнению с существующими подходами, провести более детальный анализ вариантов конфигураций СУД МКА. Так, если оценивать варианты конфигураций с позиции классической теории надежности, то первые шесть вариантов неразличимы. Однако оценки этих вариантов, полученные с применением предложенного метода, имеют явное различие: применение первых четырех вариантов конфигураций СУД МКА позволяют выполнять 1 и 3 режимы ориентации, применение 5 и 6 вариантов – 1, 2 и 3 режимы ориентации.

Прокомментируем один из полученных недоминируемых вариантов конфигураций исследуемой СУД МКА под номером 13. Указанный вариант рассматриваемой системы характеризуется тремя основными показателями: суммарная масса, энергопотребление и надежность. Масса варианта №13 составляет 42,9. Энергопотребление – 147,5. В таблицах 4-5 представлены значения обобщенного показателя структурно-функциональной надежности системы для различных случаев задействования режимов ориентации, а также вероятности реализации системой отдельно взятых режимов. Наконец, итоговым значением показателя надежности указанного варианта, высчитываемого как центр тяжести нечеткого трапециевидного числа, является значение 0,992932.

Структурно вариант №13 включает в себя первые два элемента типа №3; третий, пятый и шестой элементы типа №6; десятый ФЭ типа №2; остальные элементы выбраны типа №1.

Выбор конкретного варианта конфигурации рассматриваемой системы из множества недоминируемых вариантов осуществляется ЛПР в интерактивном режиме. Для этого ЛПР указывает дополнительную информацию в виде допустимых значений на ограничения массы, энергопотребления и/или надежности.

**6. Заключение.** В настоящей работе представлен метод структурно-параметрического синтеза конфигураций MrO для формирования требуемого множества эффективных вариантов его конфигураций, равномерно расположенных в множестве компромиссов (множестве Парето), в основе которого лежит концепция параметрического генома структуры MrO, совместное применение метода последовательных уступок и операторного решающего правила, а также интегральные оценки показателей структурно-функциональной надежности MrO для рассматриваемых сценариев реализации режимов функционирования.

Практическая реализация метода структурно-параметрического синтеза конфигураций MrO показала:

– параметрический геном структуры MrO позволяет в концентрированном виде хранить явные и неявные знания экспертов о взаимодействии элементов и подсистем объекта при выполнении различных комбинаций реализации режимов функционирования, определять оптимистические, пессимистические и промежуточные оценки показателей структурно-функциональной надежности однородных и неоднородных MrO, показателей значимости и вкладов отдельных ФЭ в обобщенный показатель структурно-функциональной надежности как монотонных, так и немонотонных MrO;

– разработанный комбинированный метод позволяет преодолеть критериальную неопределенность и сформировать требуемое множество эффективных решений, равномерно расположенное в области компромиссов;

– приведенные аналитические выражения для вычисления интегральных показателей структурно-функциональной надежности МрО в условиях неизвестной циклограммы режимов его функционирования дают возможность выполнять оперативные вычисления (с минимальным объемом оперативной памяти) указанных показателей и решать поставленную в статье задачу даже на бортовом интеллектуальном вычислительном комплексе МКА;

– выбор конфигураций МрО существенно зависит от вариантов задействования режимов его функционирования – совместного либо раздельного, а также равноценности данных режимов.

### Литература

1. Балухто А.Н., Романов А.А. Искусственный интеллект в космической технике: состояние, перспективы развития // Ракетно-космическое приборостроение и информационные системы. 2019. Том 6. №1. С. 65–75.
2. Mikaelyan L., Müller S., Gerndt A., Noll T. Synthesizing and Optimizing FDIR Recovery Strategies from Fault Trees // Formal Techniques for Safety-Critical Systems. FTSCS 2018. Communications in Computer and Information Science. / Artho C., Ölveczky P. (eds). Springer, Cham. 2019. vol. 1008. [https://doi.org/10.1007/978-3-030-12988-0\\_3](https://doi.org/10.1007/978-3-030-12988-0_3)
3. Tiplaldi M., Glielmo L. A Survey on Model-Based Mission Planning and Execution for Autonomous Spacecraft // IEEE Systems Journal. 2018. vol. 12. Issue 4. pp. 3893–3905.
4. Lianxiang J., Peipei X., Xuyang F. Software Reconfiguration Technology for Serviceable Satellite OBDH System // Proceedings of the Second International Conference on Mechanical, Control and Computer Engineering (ICMCCE), Harbin. 2017. pp. 100–104.
5. Amigoni F., Ferrari Dacrema M., Donati A., Laroque C., Lavagna M., Riva A. Aggregating Models for Anomaly Detection in Space Systems: Results from the FCTMAS Study // Intelligent Autonomous Systems 15. IAS 2018. Advances in Intelligent Systems and Computing, Strand / Dillmann R., Menegatti E., Ghidoni S. (eds). 2019. vol. 867. Springer, Cham. [https://doi.org/10.1007/978-3-030-01370-7\\_12](https://doi.org/10.1007/978-3-030-01370-7_12).
6. Wang D.-Y., Tu Y.-Y., Liu C.-R., He Y.-Z., Li W.-B. Connotation and Research of Reconfigurability for Spacecraft Control Systems: A Review // Acta Automatica Sinica. 2017. vol. 43. no. 10. pp. 1687–1702.
7. Nayak A., Reyes Levalle R., Lee S., Nof S.Y. Resource sharing in cyber-physical systems: modelling framework and case studies // International Journal of Production Research. 2016. vol. 54. no. 23. pp. 6969–6983.
8. Theorin A. An event-driven manufacturing information system architecture for Industry 4.0 // International Journal of Production Research. 2016. pp. 1297–1311.



9. Battaia O., Dolgui A., Guschinsky N. Decision support for design of reconfigurable rotary machining systems for family part production // *International Journal of Production Research*. 2017. vol. 55. no. 5. pp. 1368–1385.
10. Севастьянов Н.Н., Андреев А.И. Основы управления надежностью космических аппаратов с длительными сроками эксплуатации: учебное пособие // М-во образования и науки Российской Федерации, Томский гос. ун-т, ОАО "Газпром космические системы". Томск: Изд. дом Томского гос. ун-та. 2015. 265 с.
11. Черкесов Г.Н., Недосекин А.О., Виноградов В.В. Анализ функциональной живучести структурно-сложных технических систем // *Надежность – 2018*. Т. 18. №2. 2018. С. 17 – 24.
12. Mehdi Jafari. Optimal redundant sensor configuration for accuracy increasing in space inertial navigation system // *Aerospace Science and Technology*. vol. 47. 2015. pp. 467-472
13. Райкунова Г.Г. Ионизирующие излучения космического пространства и их воздействие на бортовую аппаратуру космических аппаратов // М.: Физматлит. 2013. 256 с.
14. Букатова И.Л. Эволюционное моделирование и его приложения. М.: Наука. 1979. 232 с.
15. Куренков В.И., Капитонов В.А. Методы расчёта и обеспечения надёжности ракетно-космических комплексов: учебное пособие // Самара: изд-во Самарского государственного аэрокосмического университета. 2007. 320 с.
16. Поленин В. И., Рябинин И. А., Свирин С. К., Гладкова И. А. Применение общего логико-вероятностного метода для анализа технических, военных организационно-функциональных систем и вооруженного противоборства: монография, научное издание // под ред. А. С. Можаяева. СПб.: СПб-региональное отделение РАЕН, 2011. 416 с.
17. Павлов А. Н., Воротягин В. Н., Кулаков А. Ю., Умаров А. Б. Исследование структурно-функциональной надёжности малых космических аппаратов при решении задач ориентации // *Информатизация и связь*. М.: Автономная некоммерческая организация "Редакция журнала "Информатизация и связь". 2020. №4. С. 156–164.
18. Павлов А.Н., Павлов Д.А., Умаров А.Б. Метод оценивания показателей живучести бортовых систем малых космических аппаратов в условиях изменяющихся режимов функционирования и деструктивных воздействий // *Труды МАИ*. 2021. №120. С. 1–29.
19. Pavlov A.N., Pavlov D.A., Vorotyagin V.N., Umarov A.B. Structural and functional analysis of supply chain reliability in the presence of demand fluctuations // *Proceedings of Models and Methods for Researching Information Systems in Transport 2020 (MMRIST 2020)*. St. Petersburg, Russian Federation, Dec. 11-12, 2020. CEUR-WS 2021. 2021. vol. 2803. pp. 61-66.
20. Павлов А.Н., Павлов Д.А., Алешин Е.Н., Воротягин В.Н., Умаров А.Б. Моделирование и анализ структурно-функциональной надежности сложных многорежимных объектов // *Труды ВКА имени А.Ф. Можайского*. 2021. №677. С. 186-194.
21. Pavlov A.N., Umarov A.B., Aleshin Ye.N. Study of the structural significance of supply chain elements with variable order rate // *Intelligent Transport Systems. Transport Security – 2021*. CEUR-WS 2021. 2021. vol-2924. pp. 1-8
22. Филатов А.В., Ткаченко И.С., Тюгашев Е.В., Сопченко Е.В. Математическое обеспечение системы управления движением МКА // *Информационные технологии и нанотехнологии*. Материалы Международной конференции и молодежной школы. Федеральное государственное автономное образовательное учреждение высшего образования «Самарский государственный

- аэрокосмический университет имени академика С.П. Королева (Национальный исследовательский университет)», Самара. 2015. С. 290-294.
23. Васильков Ю.В., Тимошенко А.В., Советов В.А., Кирмель А.С. Методика оценки функциональных характеристик систем радиомониторинга при ограниченных данных о параметрах надежности // Труды МАИ. 2019. №108. DOI: 10.34759/trd-2019-108-16.
  24. Manuilov Yu.S., Pavlov D.A., Pavlov A.N., Slin'ko A.A. The Technique of Informational Interaction Structural-parametric Optimization of a Earth's Remote sensing Small Spacecraft Cluster // Springer International Publishing, Switzerland. 2018. vol. 3: Cybernetics and Algorithms in Intelligent Systems. pp. 155-166.
  25. Ларичев О.И. Вербальный анализ решений // М.: Наука. 2006. 181 с.
  26. Бородин В.В. Оценка надежности обслуживаемых устройств орбитальной космической станции // Труды МАИ. 2012. №58. 12 с.
  27. ГОСТ 27.003-90. Надежность в технике. Состав и общие правила задания требований по надежности. 1990.
  28. Колодежный Л.П., Черномаров А.В. Надежность и техническая диагностика // М.: Изд. ВВА им. проф. Н.Е. Жуковского и Ю.А. Гагарина. 2010. 452 с.
  29. Подиновский В. В., Ногин В. Д. Парето-оптимальные решения многокритериальных задач // М.: Наука. 1982. 254 с.
  30. Калинов М.И., Родионов В.А. Обоснование выбора рационального варианта применения малых космических аппаратов при отказах отдельных элементов их бортовых систем // IX всероссийская научно-практическая конференция по имитационному моделированию и его применению в науке и промышленности (ИММОД-2019), 2019. С. 434-438.
  31. Кини Р.Л., Райфа Х. Принятие решений при многих критериях: предпочтения и замещения // М.: Радио и связь. 1981. 560 с.
  32. Ногин В.Д. Принятие решений в многокритериальной среде: количественный подход // М.: Физматлит. 2005. 176 с.
  33. Ногин В.Д. Проблемы сужения множества Парето: подходы к решению // Искусственный интеллект и принятие решений. 2008. № 1. С. 98–112.
  34. Москвин Б.В. Теория принятия решений: учебник // СПб.: ВКА им. А.Ф.Можайского, 2014. 383 с.
  35. Pavlov A., Ivanov D., Dolgui A., Sokolov V. Hybrid Fuzzy-Probabilistic Approach to Supply Chain Resilience Assessment. IEEE Transactions on Engineering Management, 65(2). 2018. pp. 303-315.
  36. Охтилев М.Ю., Соколов Б.В., Юсупов Р.М. Интеллектуальные технологии мониторинга и управления структурной динамикой сложных технических объектов // М.: Наука. 2006. 410 с.
  37. Быков А.П., Пиганов М.Н. Прогнозирование показателей качества бортовых радиоэлектронных устройств // Труды МАИ. 2021. №116. [http://mai.ru/upload/iblock/bdd/Bykov\\_Piganov\\_rus\\_eng.pdf](http://mai.ru/upload/iblock/bdd/Bykov_Piganov_rus_eng.pdf). DOI: 10.34759/trd-2021-116-05.
  38. Кирилин А.Н., Ахметов Р.Н., Шахматов Е.В., Ткаченко С.И., Бакланов А.И., Салмин В.В., Семкин Н.Д., Ткаченко И.С., Горячкин О.В. Опытнотехнологический малый космический аппарат «АИСТ-2Д» // Самара: Изд-во СамНЦ РАН, 2017. 324 с.
  39. Шипов М.Г. Гашение угловых скоростей КА «Аист-2Д» с использованием системы сброса кинетического момента // Вестник самарского университета. Авиационная и ракетно-космическая техника. 2019. Т. 18. №2. С. 121-127.

**Павлов Александр Николаевич** — д-р техн. наук, профессор, профессор кафедры, кафедра автоматизированных систем управления космических комплексов, Военно-космическая академия имени А.Ф. Можайского; ведущий научный сотрудник, лаборатория информационных технологий в системном анализе и моделировании, Санкт-Петербургский Федеральный исследовательский центр Российской академии наук (СПб ФИЦ РАН)). Область научных интересов: системный анализ и принятие решений в условиях существенной неопределенности, теория управления структурной динамикой сложных организационно-технических систем. Число научных публикаций — 300. pavlov62@list.ru; улица Ждановская, 13, 197198, Санкт-Петербург, Россия; р.т.: +7(911)259-7153.

**Павлов Дмитрий Александрович** — канд. техн. наук, преподаватель, кафедра технологий и средств комплексной обработки и передачи информации в автоматизированных системах управления, Военно-космическая академия имени А.Ф. Можайского. Область научных интересов: разработка научных основ теории управления структурной динамикой сложных организационно-технических систем. Число научных публикаций — 70. dpavlov239@mail.ru; улица Ждановская, 13, 197198, Санкт-Петербург, Россия; р.т.: +7(963)348-2310.

**Умаров Александр Бахтиёрович** — адъюнкт, кафедра автоматизированных систем управления космических комплексов, Военно-космическая академия имени А.Ф. Можайского. Область научных интересов: разработка научных основ теории управления структурной динамикой сложных организационно-технических систем. Число научных публикаций — 12. antropicier737@gmail.com; улица Ждановская, 13, 197198, Санкт-Петербург, Россия; р.т.: +7(911)213-2123.

**Гордеев Андрей Владимирович** — адъюнкт, кафедра автоматизированных систем управления космических комплексов, Военно-космическая академия имени А.Ф. Можайского. Область научных интересов: разработка научных основ теории управления структурной динамикой сложных организационно-технических систем. Число научных публикаций — 10. grd611@bk.ru; улица Ждановская, 13, 197198, Санкт-Петербург, Россия; р.т.: +7(999)002-2598.

**Поддержка исследований.** Исследования, выполненные по данной тематике, проводились при частичной финансовой поддержке грантов РФФИ (№№20-08-01046), в рамках бюджетной темы FZFF-2022-0004.

A. PAVLOV, D. PAVLOV, A. UMAROV, A. GORDEEV  
**METHOD OF STRUCTURAL-PARAMETRIC SYNTHESIS OF  
CONFIGURATION MULTI-MODE OBJECT**

*Pavlov A., Pavlov D., Umarov A., Gordeev A. Method of Structural-Parametric Synthesis of Configuration Multi-Mode Object.*

**Abstract.** The complexity of modern objects with a reconfigurable structure leads to the need to take into account various factors of their interaction with the environment and is associated with an increase in the number of their constituent elements and subsystems, as well as, accordingly, a rapid increase in the number of internal connections, and manifests itself in such aspects as structural complexity, complexity of functioning, complexity of choice of behavior, complexity of modeling and complexity of development. These systems operate in conditions of significant uncertainty associated with a change in the content of the goals and objectives facing the object, the impact of disturbing factors from the external environment and having a targeted and / or non-targeted character. These aspects of the complexity of the system are associated not only with the uncertain effects of the external environment, but also with many different modes (types) of functioning, corresponding to the multiplicity of tasks being solved and the multiplicity of indicators of the quality of their solution. As a rule, systems with a fixed structure, usually tuned to a steady (some given) mode, do not provide the best control quality in other modes. Therefore, the multi-mode and uncertainty of the operating conditions necessitate solving the problem of analysis and synthesis of the configuration and reconfiguration of the objects under consideration, based on intelligent approaches. At the same time, at the stages of creating and designing objects with a tunable structure, such interconnected sets of modes of operation and structures should be synthesized, and, possibly, such a level of redundancy should be introduced into these sets, taking into account space-time, technical and technological restrictions, under which at the stage of their application for the intended purpose, it would be possible to respond flexibly to all design and off-design contingencies that cause structural changes in the object. From a formal point of view, the solution to these problems is possible within the framework of such an important class of modern scientific and technical problems as the problems of multi-criteria structural-functional synthesis of configurations of multi-mode objects at various stages of their life cycle. This article presents a method for solving these problems, based on the concept of the parametric genome of complex multi-mode objects proposed by the authors. The application of this concept makes it possible to store in a concentrated form the explicit and implicit knowledge of experts about the interaction of elements and subsystems of an object when performing various combinations of the implementation of operating modes, as well as to quickly calculate optimistic and pessimistic estimates of indicators of structural and functional reliability of homogeneous / heterogeneous, monotonous / non-monotonic, equivalent / unequal multi-mode objects. With a multi-criteria choice of the required number of non-dominated variants of configurations of a multi-mode object, evenly distributed in the set of effective (Pareto) alternatives, a combination of the method of interval lexicographic ordering (successive concessions) and an operator decision rule was proposed. At the same time, in order to conduct a detailed analysis of the possibility of implementing an object of joint or separate activation of operating modes with an equivalent or unequal intensity of their use, a fuzzy-possibility representation of a generalized indicator of structural and functional reliability in the form of a trapezoidal number and determining its center of gravity was proposed. The results of applying the developed method of structural-parametric synthesis of configurations of a multi-mode object with a tunable structure are presented on the example of the motion control system of the small spacecraft "Aist-2D".

---

**Keywords:** configuration synthesis, multi-mode object, multi-criteria, set of non-dominated alternatives, parametric genome.

---

## References

1. Baluhto A.N., Romanov A.A. [Artificial intelligence in space technology: state, development prospects]. *Raketno-kosmicheskoe priborostroenie i informacionnye sistemy*. [Rocket and space instrumentation and information systems]. 2019. vol. 6. no. 1. pp. 65–75. (In Russ.).
2. Mikaelyan L., Müller S., Gerndt A., Noll T. Synthesizing and Optimizing FDIR Recovery Strategies from Fault Trees. *Formal Techniques for Safety-Critical Systems. FTSCS 2018. Communications in Computer and Information Science*. Artho C., Ölveczky P. (eds). Springer, Cham. 2019. vol. 1008. [https://doi.org/10.1007/978-3-030-12988-0\\_3](https://doi.org/10.1007/978-3-030-12988-0_3)
3. Tipaldi M., Glielmo L. A Survey on Model-Based Mission Planning and Execution for Autonomous Spacecraft. *IEEE Systems Journal*. 2018. vol. 12. Issue 4. pp. 3893–3905.
4. Lianxiang J., Peipei X., Xuyang F. Software Reconfiguration Technology for Serviceable Satellite OBDH System. *Proceedings of the Second International Conference on Mechanical, Control and Computer Engineering (ICMCCE)*, Harbin. 2017. pp. 100–104.
5. Amigoni F., Ferrari Dacrema M., Donati A., Laroque C., Lavagna M., Riva A. Aggregating Models for Anomaly Detection in Space Systems: Results from the FCTMAS Study. *Intelligent Autonomous Systems 15. IAS 2018. Advances in Intelligent Systems and Computing*, Strand. Dillmann R., Menegatti E., Ghidoni S. (eds). 2019. vol. 867. Springer, Cham. [https://doi.org/10.1007/978-3-030-01370-7\\_12](https://doi.org/10.1007/978-3-030-01370-7_12).
6. Wang D.-Y., Tu Y.-Y., Liu C.-R., He Y.-Z., Li W.-B. Connotation and Research of Reconfigurability for Spacecraft Control Systems: A Review. *Acta Automatica Sinica*. 2017. vol. 43. no. 10. pp. 1687–1702.
7. Nayak A., Reyes Levalle R., Lee S., Nof S.Y. Resource sharing in cyber-physical systems: modelling framework and case studies. *International Journal of Production Research*. 2016. vol. 54. no. 23. pp. 6969–6983.
8. Theorin A. An event-driven manufacturing information system architecture for Industry 4.0. *International Journal of Production Research*. 2016. pp. 1297–1311.
9. Battaia O., Dolgui A., Guschinsky N. Decision support for design of reconfigurable rotary machining systems for family part production. *International Journal of Production Research*. 2017. vol. 55. no. 5. pp. 1368–1385.
10. Sevast'janov N.N., Andreev A.I. *Osnovy upravlenija nadezhnost'ju kosmicheskikh apparatov s dlitel'nymi srokami jekspluatcii: uchebnoe posobie* [Fundamentals of reliability management of spacecraft with long service life: textbook]. Izd. dom Tomskogo gos. un-ta. [Publishing house of the Tomsk state. university]. 2015. 265 p. (In Russ.).
11. Cherkesov G.N., Nedosekin A.O., Vinogradov V.V. [Analysis of functional survivability of structurally complex technical systems]. *Nadezhnost' – 2018. [Reliability-2018]*. vol. 18. no. 2. 2018. pp. 17 – 24. (In Russ.).
12. Mehdi Jafari. Optimal redundant sensor configuration for accuracy increasing in space inertial navigation system. *Aerospace Science and Technology*. vol. 47. 2015. pp. 467-472.
13. Rajkunova G.G. *Ionizirujushhie izluchenija kosmicheskogo prostranstva i ih vozdejstvie na bortovuju apparaturu kosmicheskikh apparatov* [Ionizing radiation of outer space and their impact on the onboard equipment of space vehicles]. M.: Fizmatlit. 2013. 256 p. (In Russ.).

14. Bukatova I.L. Jevoljucionnoe modelirovanie i ego prilozhenija [Evolutionary modeling and its applications]. M.: Nauka. 1979. 232 p. (In Russ.).
15. Kurenkov V.I., Kapitonov V.A. Metody raschjota i obespechenija nadjozhnosti raketno-kosmicheskikh kompleksov: uchebnoe posobie [Methods for calculating and ensuring the reliability of rocket and space systems: a tutorial]. Samara: izd-vo Samarskogo gosudarstvennogo ajerokosmicheskogo universiteta [Samara: publishing house of the Samara State Aerospace University.]. 2007. 320 p. (In Russ.).
16. Polenin V. I., Rjabinin I. A., Svirin S. K., Gladkova I. A. Primenenie obshhego logiko–verojatnostnogo metoda dlja analiza tehniceskikh, voennyh organizacionno–funkcional'nyh sistem i voozrzhennogo protivoborstva: monografija, nauchnoe izdanie [Application of the general logical-probabilistic method for the analysis of technical, military organizational and functional systems and armed confrontation: monograph, scientific edition]. SPb.: SPb–regional'noe otdelenie RAEN [SPb: St. Petersburg Regional Branch of the Russian Academy of Natural Sciences]. 2011. 416 p. (In Russ.).
17. Pavlov A. N., Vorotjagin V. N., Kulakov A. Ju., Umarov A. B. [Study of the structural and functional reliability of small space vehicles in solving problems of orientation]. M.:Avtonomnaja nekommercheskaja organizacija "Redakcija zhurnala "Informatizacija i svjaz" [M.:Autonomous non-profit organization "Editorial office of the journal "Informatization and Communication"]. 2020. no. 4. pp. 156–164. (In Russ.).
18. Pavlov A.N., Pavlov D.A., Umarov A.B. [Method for estimating the survivability indicators of onboard systems of small spacecraft under conditions of changing modes of operation and destructive impacts]. Trudy MAI [Proceedings of the MAI]. 2021. no. 120. pp. 1–29. (In Russ.).
19. Pavlov A.N., Pavlov D.A., Vorotyagin V.N., Umarov A.B. Structural and functional analysis of supply chain reliability in the presence of demand fluctuations. Proceedings of Models and Methods for Researching Information Systems in Transport 2020 (MMRIST 2020). St. Petersburg, Russian Federation, Dec. 11-12, 2020. CEUR-WS 2021. 2021. vol. 2803. pp. 61-66.
20. Pavlov A.N., Pavlov D.A., Aleshin E.N., Vorotjagin V.N., Umarov A.B. [Modeling and analysis of structural and functional reliability of complex multi-mode objects]. Trudy VKA imeni A.F. Mozhajskogo [Proceedings of the VKA named after A.F. Mozhaisky.] 2021. №677. pp. 186-194. (In Russ.).
21. Pavlov A.N., Umarov A.B., Aleshin Ye.N. Study of the structural significance of supply chain elements with variable order rate // Intelligent Transport Systems. Transport Security – 2021. CEUR-WS 2021. 2021. vol-2924. pp. 1-8.
22. Filatov A.V., Tkachenko I.S., Tjugashev E.V., Sopchenko E.V. [Mathematical support of the small spacecraft motion control system]. Informacionnye tehnologii i nanotehnologii. Materialy Mezhdunarodnoj konferencii i molodezhnoj shkoly. Federal'noe gosudarstvennoe avtonomnoe obrazovatel'noe uchrezhdenie vysshego obrazovanija «Samarskij gosudarstvennyj ajerokosmicheskij universitet imeni akademika S.P. Koroleva (Nacional'nyj issledovatel'skij universitet)» [Information technologies and nanotechnologies. Materials of the International Conference and Youth School. Federal State Autonomous Educational Institution of Higher Education "Samara State Aerospace University named after Academician S.P. Queen (National Research University)"]. Samara. 2015. pp. 290-294. (In Russ.).
23. Vasil'kov Ju.V., Timoshenko A.V., Sovetov V.A., Kirmel' A.S. [Methodology for assessing the functional characteristics of radio monitoring systems with limited data on reliability parameters]. Trudy MAI [Proceedings of the MAI]. 2019. №108. DOI: 10.34759/trd-2019-108-16. (In Russ.).

24. Manuilov Yu.S., Pavlov D.A., Pavlov A.N., Slin'ko A.A. The Technique of Informational Interaction Structural-parametric Optimization of a Earth's Remote sensing Small Spacecraft Cluster // Springer International Publishing, Switzerland. 2018. vol. 3: Cybernetics and Algorithms in Intelligent Systems. pp. 155-166.
25. Larichev O.I. Verbal'nyj analiz reshenij [Verbal decision analysis]. M.: Nauka. 2006. 181 p. (In Russ.).
26. Borodin V.V. [Evaluation of the reliability of serviceable devices of the orbital space station]. Trudy MAI [Proceedings of the MAI]. 2012. №58. 12 p. (In Russ.).
27. GOST 27.003-90. [Reliability in technology. Composition and general rules for setting reliability requirements]. 1990. (In Russ.).
28. Kolodezhnyj L.P., Chernodarov A.V. Nadezhnost' i tehničeskaja diagnostika [Reliability and technical diagnostics]. M.: Izd. VVA im. prof. N.E. Zhukovskogo i Ju.A. Gagarina. 2010. 452 p. (In Russ.).
29. Podinovskij V. V., Nogin V. D. [Pareto-optimal solutions to multiobjective problems]. M.: Nauka. 1982. 254 p. (In Russ.).
30. Kalinov M.I., Rodionov V.A. [Justification of the choice of a rational option for the use of small spacecraft in case of failures of individual elements of their onboard systems]. IX vserossijskaja nauchno-praktičeskaja konferencija po imitacionnomu modelirovaniju i ego primeneniju v nauke i promyšlennosti (IMMOD-2019) [IX All-Russian Scientific and Practical Conference on Simulation Modeling and its Application in Science and Industry (IMMOD-2019)]. 2019. pp. 434-438. (In Russ.).
31. Kini R.L., Rajfa H. [Decision Making Under Multiple Criteria: Preferences and Substitutions]. M.: Radio i svjaz' [M.: Radio and communication.]. 1981. 560 p. (In Russ.).
32. Nogin V.D. [Decision Making in a Multicriteria Environment: A Quantitative Approach]. M.: Fizmatlit. 2005. 176 p. (In Russ.).
33. Nogin V.D. [Problems of narrowing the Pareto set: approaches to the solution]. Iskusstvennyj intellekt i prinjatje reshenij [Artificial intelligence and decision making]. 2008. № 1. pp. 98-112. (In Russ.).
34. Moskvina B.V. Teorija prinjatija reshenij: učebnik [Decision Theory: Textbook]. Spb.: VKA im. A.F.Mozhajsckogo. 2014. 383 p. (In Russ.).
35. Pavlov A., Ivanov D., Dolgui A., Sokolov B. Hybrid Fuzzy-Probabilistic Approach to Supply Chain Resilience Assessment. IEEE Transactions on Engineering Management, 65(2). 2018. pp. 303-315. (In Russ.).
36. Ohtilev M.Ju., Sokolov B.V., Jusupov R.M. [Intelligent Technologies for Monitoring and Controlling the Structural Dynamics of Complex Technical Objects]. M.: Nauka. 2006. 410 p. (In Russ.).
37. Bykov A.P., Piganov M.N. [Forecasting quality indicators of on-board radio electronic devices]. Trudy MAI [Proceedings of the MAI]. 2021. №116. [http://mai.ru/upload/iblock/bdd/Bykov\\_Piganov\\_rus\\_eng.pdf](http://mai.ru/upload/iblock/bdd/Bykov_Piganov_rus_eng.pdf). DOI: 10.34759/trd-2021-116-05. (In Russ.).
38. Kirilin A.N., Ahmetov R.N., Shahmatov E.V., Tkachenko S.I., Baklanov A.I., Salmin V.V., Semkin N.D., Tkachenko I.S., Gorjachkin O.V. [Experimental and technological small spacecraft "AIST-2D"]. Samara: Izd-vo SamNC RAN [Samara: Publishing House of SamNTs RAS]. 2017. 324 p. (In Russ.).
39. Shipov M.G. [Angular velocity suppression of the Aist-2D spacecraft using the angular momentum release system]. Vestnik samarskogo universiteta. Aviacionnaja i raketno-kosmicheskaja tehnika [Bulletin of the Samara University. Aviation and rocket and space technology]. 2019. vol. 18. no. 2. pp. 121-127. (In Russ.).

**Pavlov Alexander** — Ph.D., Dr.Sci., Professor, Professor of the department, Department automated control systems space complexes, Mozhaisky Military Space Academy; Senior researcher, Laboratory for information technologies in systems analysis and modeling, St. Petersburg Federal Research Center of the Russian Academy of Sciences (SPC RAS). Research interests: systems analysis and operations research by conditions of substantial uncertainty, the control theory by structural dynamics of complex organizational-technical systems. The number of publications — 300. pavlov62@list.ru; 13, Zhdanovskaya St., 197198, St. Petersburg, Russia; office phone: +7(911)259-7153.

**Pavlov Dmitry** — Ph.D., Teacher, Department of technologies and tools for complex processing and transmission of information in an automated control system, Mozhaisky Military Space Academy. Research interests: development of scientific bases of control theory by structural dynamics of complex organizational-technical systems. The number of publications — 70. dpavlov239@mail.ru; 13, Zhdanovskaya St., 197198, St. Petersburg, Russia; office phone: +7(963)348-2310.

**Umarov Alexander** — Post-graduate student, Department automated control systems space complexes, Mozhaisky Military Space Academy. Research interests: development of scientific bases of control theory by structural dynamics of complex organizational-technical systems. The number of publications — 12. antropicier737@gmail.com; 13, Zhdanovskaya St., 197198, , Russia; office phone: +7(911)213-2123.

**Gordeev Andrey** — Post-graduate student, Department automated control systems space complexes, Mozhaisky Military Space Academy. Research interests: development of scientific bases of control theory by structural dynamics of complex organizational-technical systems. The number of publications — 10. grd611@bk.ru; 13, Zhdanovskaya St., 197198, St. Petersburg, Russia; office phone: +7(999)002-2598.

**Acknowledgements.** Research carried out on this topic was carried out with partial financial support from RFBR grants (No. 20-08-01046), under the budget theme FFZF-2022-0004.



## Руководство для авторов

Взаимодействие автора с редакцией осуществляется через личный кабинет на сайте журнала «Информатика и автоматизация» <http://ia.spcras.ru/>. При регистрации авторам рекомендуется заполнить все предложенные поля данных. Подготовка статьи ведется с помощью текстовых редакторов MS Word 2007 и выше или LaTeX. Объем основного текста (до раздела Литература) - от 20 до 30 страниц включительно. Переносы разрешены. Номера страниц не проставляются. Основная часть текста статьи разбивается на разделы, среди которых являются обязательными: введение, хотя бы один «содержательный» раздел и заключение. Допускается также мотивированное содержанием и структурой материал а выделение подразделов. В основную часть опускается помещать рисунки, таблицы, листинги и формулы. Правила их оформления подробно рассмотрены на нашем сайте в разделе «Руководство для авторов».

## Author guidelines

Interaction between each potential author and the Editorial board is realized through the pesoal account on the website of the journal "Informatics and Automation" <http://ia.spcras.ru/>. At the registration the authors are requested to fill out all data fields in the proposed form. The submissions should be prepared using MS Word 2007, LaTeX. The text of the paper in the main part should not exceed 30 pages. Pages are not numbered; hyphenations are allowed. Certain figures, tables, listings and formulas are allowed in the main section, and their typography is considered in more detail at the journal web.

---

Signed to print 01.08.2022

Printed in Publishing center GUAP, 67 litera A, B. Morskaya, St. Petersburg, Russia, 190000

---

The journal is registered in the Russian Federal Agency for Communications and Mass-Media Supervision, certificate ПИ № ФС77-79228 dated September 25, 2020  
Subscription Index П5513, Russian Post Catalog

---

Подписано к печати 01.08.2022. Формат 60×90 1/16. Усл. печ. л. 12,26. Заказ № 293.

Тираж 300 экз., цена свободная.

Отпечатано в Редакционно-издательском центре ГУАП,  
190000, Санкт-Петербург, Б. Морская, д. 67, лит. А

---

Журнал зарегистрирован Федеральной службой по надзору в сфере связи и массовых коммуникаций, свидетельство ПИ № ФС77-79228 от 25 сентября 2020 г.

Подписной индекс П5513 по каталогу «Почта России»