

**СИСТЕМНЫЙ АНАЛИЗ
И ПРИКЛАДНАЯ
ИНФОРМАТИКА**

№ 1, 2023



**SYSTEM ANALYSIS
AND APPLIED
INFORMATION SCIENCE**

No 1, 2023

**Международный
Научно-технический журнал**

Издается с декабря 2012 года

Учредитель

Белорусский национальный
технический университет

Главный редактор

Сергей Васильевич Харитончик

Редакционная коллегия

Д. В. Капский (зам. главного редактора),
А. М. Авсиевич, А. А. Большаков (РФ),
В. А. Вишняков, Л. С. Герасимович,
А. В. Гулай, Н. Н. Гурский,
Г. О. Кипиани (Грузия),
А. С. Климчик (РФ), А. А. Лобатый,
В. А. Малкин, А. В. Малолетов (РФ),
Ф. М. Нуралиев (Узбекистан),
И. А. Сатиков (ответственный секретарь),
В. В. Старовойтов, Ю. Ф. Яцына

**International
Science and Technical Journal**

Published since December, 2012

Founder

Belarusian National
Technical University

Editor-in-chief

Sergei V. Kharytonchyk

Editorial board

D. Kapski (deputy editor-in-chief),
A. Ausiyevich, A. Bolshakov (RF),
V. Vishnyakou, L. Gerasimovich,
A. Gulaj, N. Gursky,
G. Kipiani (Georgia),
A. Klimchik (RF), A. Lobaty,
V. Malkin, A. Maloletov (RF),
F. Nuraliev (Uzbekistan),
I. Satikov (executive secretary),
V. Starovoitov, U. Yatsyna

Журнал включен в "Перечень научных изданий Республики Беларусь
для опубликования результатов диссертационных исследований"

Журнал включен в международные каталоги и базы данных:

- | | |
|--|---------------|
| ❖ Российский индекс научного цитирования (РИНЦ) | ❖ EBSCO |
| ❖ Научная электронная библиотека eLIBRARY.RU | ❖ BASE Search |
| ❖ Электронно-библиотечная система (ЭБС) издательства Лань | ❖ OpenAIRE |
| ❖ DOAJ https://doaj.org/toc/2414-0481 | ❖ WorldCat |
| ❖ Google Scholar | ❖ OpenDOAR |
| ❖ Киберленинка | ❖ ROAR |

Ответственный секретарь редакции

И. А. Сатиков

Технический редактор

О. Л. Чабарова

Адрес редакции

ул. Франциска Скорины 25/3, Минск, 220114,
Республика Беларусь
Тел. +375 17 266-26-58
e-mail: ca_pi@bntu.by

Executive secretary of the editorial board

I. Satikov

Technical Editor

V. Chabarava

Editorial board address

25/3 Franciska Skariny str., Minsk, 220114,
Republic of Belarus
Tel. +375 17 266-26-58
e-mail: ca_pi@bntu.by

Свидетельство о государственной регистрации средства массовой информации
№1540 от 08.06.2012, выданное Министерством информации Республики Беларусь

Подписано в печать 14.06.2023. Формат бумаги 60x84 1/8. Бумага мелованная.

Цифровая печать. Усл. печ. л. 7,21. Уч.-изд. л. 5,01. Тираж 18 экз. Заказ 535.

Отпечатано в БНТУ. ЛП № 02330/74 от 03.03.2014.

220013, г. Минск, пр. Независимости, 65.

СОДЕРЖАНИЕ

УПРАВЛЕНИЕ ТЕХНИЧЕСКИМИ ОБЪЕКТАМИ

Сидоренко А.В., Солодухо Н.А.
Огибание препятствий при перемещении мобильного робота.....4

Лобатый А.А., Гу Пэнхао
Математическое моделирование движения летательных аппаратов мультироторного типа.....10

Шейников А.А., Иваницкий Л.А., Малкин В.А.
Анализ погрешностей датчика авиагоризонта на базе системы технического зрения.....16

ОБРАБОТКА ИНФОРМАЦИИ И ПРИНЯТИЕ РЕШЕНИЙ

Лукашевич М.М.
Нейросетевой классификатор для определения диабетической ретинопатии по изображениям сетчатки.....25

Vishniakou U.A. Shaya B.H.t
Methodics and tools of cough sound processing on basic of neural net.....35

Гируцкий И.И., Сеньков А.Г., Ракевич Ю.А.
Статистический алгоритм обработки термографических снимков вымени коровы для диагностики мастита с использованием критерия Байесса.....42

Золотарев С.А., Таруат А.Т., Биленко Э.Г.
Итерационная реконструкция медицинских фантомов на вычислительном кластере EAGLE.....47

ЗАЩИТА ИНФОРМАЦИИ

Иваниук А.А., Шамына А.Ю.
Физически неклонированная функция типа АБИТР с нелинейными парами путей.....54

CONTENTS

MANAGMENT OF TECHNICAL OBJECTS

Sidorenko A.V., Saladukha N.A.
Bending obstacles when moving a mobile robot.....4

Lobaty A.A., Gu Penghao
Mathematical modeling of movement of multi-rotor type aircraft.....10

Sheinikov A.A., Ivanitski L.A., Malkin V.A.
Analysis of errors of the artificial horizon sensor based on vision system.....16

DATA PROCESSING AND DESICION-MAKING

Lukashevich M.M.
A neural network classifier for detecting diabetic retinopathy from retinal images.....25

Vishniakou U.A. Shaya B.H.t
Methodics and tools of cough sound processing on basic of neural net.....35

Hirutsky I.I., Senkov A.G., Rakevitch Y.A.
Statistical bayesian algorithm for processing thermographic images of the cow udder for diagnosing mastitis.....42

Zolotarev C.A., Taruat A.T., Bilenko E.G.
Iterative reconstruction on medical phantoms on the computing cluster of eagle.....47

INFORMATION SECURITY

Ivaniuk A.A., Shamyna A.Yu.
Physically non-cloneable Arbiter -type function with non-linear path pairs.....54

**УПРАВЛЕНИЕ
ТЕХНИЧЕСКИМИ
ОБЪЕКТАМИ**

**MANAGEMENT
OF TECHNICAL
OBJECTS**

СИДОРЕНКО А.В., СОЛОДУХО Н.А.

ОГИБАНИЕ ПРЕПЯТСТВИЙ ПРИ ПЕРЕМЕЩЕНИИ МОБИЛЬНОГО РОБОТА

Факультет радиофизики и компьютерных технологий
Белорусского государственного университета
г. Минск, Республика Беларусь

Рассмотрены вопросы моделирования при навигации с огибанием препятствий мобильного робота с использованием методов машинного обучения: Q -обучения, алгоритма SARSA, глубокого Q -обучения и двойного глубокого Q -обучения. Разработанное программное обеспечение включает средства *Mobile Robotics Simulation Toolbox*, *Reinforcement Learning Toolbox* и пакет визуализации *Gazebo* для моделирования среды. Результаты вычислительного эксперимента показывают, что для моделируемой среды размером 17 на 17 клеток и препятствия длиной в 12 клеток обучение при использовании алгоритма SARSA происходит с лучшей производительностью, чем для остальных.

Предложен алгоритм огибания препятствий с исключением методов машинного обучения, и показано, что скорость огибания препятствий роботом с использования данного алгоритма выше, чем скорость обучения при применении глубокого Q -обучения и двойного глубокого Q -обучения, но ниже, чем с использованием алгоритмов SARSA и Q -обучения. Для предложенного алгоритма проведен вычислительный эксперимент с использованием среды моделирования движения робота. В пакете визуализации *Gazebo* 11 показано, что препятствия кубической формы огибаются быстрее, чем цилиндрической.

Ключевые слова: робот, машинное обучение, Q -обучение, перемещение, препятствия.

Введение

Интеграция мобильных роботов в военную, производственную, космическую сферы деятельности человека сталкивается с одной из актуальных проблем – управление движением мобильного робота в некоторой среде при известном местоположении робота, расположении целевых точек, в которые должен переместиться робот [1]. При этом существенным является обеспечение безопасного движения робота без столкновения со встречающимися на его пути препятствиями.

При решении подобных задач, как правило, используются алгоритмы машинного обучения, включающие алгоритмы обучения с подкреплением, нейросетевые алгоритмы, алгоритмы глубокого обучения [2-4]. Использование указанных алгоритмов основано на принципах моделирования. Критерием оптимизации в каждой из указанных моделей является определение количества эпизодов для обучения алгоритма.

В работе [4] проведены исследования и проанализирована реализация алгоритмов машинного обучения с подкреплением при использовании симуляции движения робота в пакете *Matlab* и определены значения вознаграждения.

В данной работе проводится сравнительный анализ алгоритмов машинного обучения для безопасного движения мобильного робота, демонстрация возможностей созданного программного обеспечения и проведение вычислительного эксперимента при навигации робота с использованием пакета визуализации *Gazebo* 11.

Проведение вычислительного эксперимента

Программно реализованные алгоритмы обучения, примененные к разработанной нами модели управления системы мобильных роботов, позволили провести вычислительный эксперимент с использованием разработанной компьютерной программы. Для реализации алгоритма обучения использовался пакет для *Matlab Reinforcement Learning Toolbox* [5]. В модели, описывающей движение робота, применялся пакет *Mobile Robotics Simulation Toolbox* [6] на операционной системе *Linux* при использовании пакета визуализации среды *Gazebo* 11. Взаимодействие агентов обеспечивается через пакет для *Matlab ROS Toolbox* [7]. В основе пространства, в котором обучался двигаться робот лежит симуляционное пространство в *Gazebo* 11 (рисунок 1).




Рисунок 1. Симуляционное пространство в пакете визуализации *Gazebo* 11

При проведении вычислительного эксперимента в качестве среды использовалась поверхность 17 на 17 клеток с препятствием в 12 клеток (рисунок 2). Для достижения защиты от ошибочного пересечения препятствий клетки стены из *Gazebo* в симуляции *Matlab* были окружены дополнительным слоем стены сверху, снизу и справа. В процессе экс-

перимента при перемещении робота достижение значения вознаграждения в численном выражении, равное 500, определялось как целевое. В любом другом местоположении отмечалось как “-1”. Обучение прекращается, когда суммарное среднее (среднее значение за последние 30 эпизодов обучения) значение вознаграждения достигает “450”.




Рисунок 2. Вид симуляции движения робота в пакете *Matlab* при обучении с помощью алгоритмов Q -обучения (а), *SARSA* (б), глубокого Q -обучения (в) и двойного глубокого Q -обучения (г)

При выполнении исследования мультиагентная система проходила оптимальный путь следования при огибании препятствия и использовании для

обучения приведенных выше алгоритмов машинного обучения. Результаты вычислительного эксперимента приведены на рисунке 3.




Рисунок 3. Графики зависимостей значений вознаграждений от количества итераций при обучении с помощью алгоритмов Q -обучения (а), *SARSA* (б). Голубая линия означает мгновенное значение вознаграждения, синяя линия – усредненное за 30 эпизодов значение вознаграждения, желтая – начальное значение Q_0 за эпизод

В работе предложен алгоритм огибания препятствий роботизированной систем в отсутствие алгоритмов машинного обучения. Используемый алгоритм движения робота с огибанием препятствий состоит из следующих этапов. В начале движения робота определяем прямую линию L , расположенную между начальной и конечной точками. Далее робот поворачивается таким образом, чтобы смотреть на конечную точку и начинает движение по прямой к конечной точке. Если в процессе движения встречается препятствие, он огибает его, двигаясь вдоль препятствия до тех пор, пока не станет на начальной

линии между начальной и конечной точками. Более подробно алгоритм движения робота представлен на рисунке 4.

При работе со симуляцией движения робота использовался визуализатор *Gazebo 11* и *ROS 2 Humble Hawksbill*. Для управления роботом использовались команды командной оболочки *UNIX bash* в *OC Linux Ubuntu 22.04 Jammy Jellyfish*. Исходный код представлен в [8]. Для работы алгоритма необходимо запустить скрипт *bash lines.sh*. Для задания конечной точки движения необходимо задать координаты X и Y в строках 332 и 333 файла *lines.sh*. В вычислитель-

ном эксперименте начальные координаты робота в пакете *Gazebo 11* составили: (0;-2), конечные – (0;9). Диаметр цилиндрических препятствий составил 0,8 единицы координатной сетки. Высота цилиндриче-

ских препятствий составила 0,5 единицы координатной сетки. Размер кубических препятствий составил 0,8x0,8x0,8 единицы координатной сетки. Размещение препятствий представлено на рисунке 5.




Рисунок 4. Алгоритм движения робота




Рисунок 5. Симуляционное пространство в пакете визуализации *Gazebo 11* при 2 (а), 1 (б), 2 (в), 1 (г) цилиндрических и кубических препятствий

Изменение времени движения при применении кубических и цилиндрических препятствиях показано на рисунке 6.

Разница времени при 1 препятствии составила 0,08 минуты, при 2 препятствиях – 4,15 минуты, при

3 препятствиях – 3,87 минуты, при 4 препятствиях – 3,24 минуты, при 5 препятствиях – 4,97 минуты. Т.е. при использовании предложенного нами алгоритма препятствия в виде кубов огибаются быстрее, чем препятствия в виде цилиндров.




Рисунок 6. График зависимость времени движения робота до цели от количества препятствий

На огибание препятствий при использовании данного алгоритма по пути к цели в симуляционном пространстве *Gazebo 11*, представленном на рисунке 1, у робота уходило $21,21 \pm 3,97$ минуты. Данное время меньше, чем время, необходимое на обучение в аналогичном пространстве в пакете *Matlab* при использовании алгоритмов глубокого Q -обучения и двойного глубокого Q -обучения, но больше, чем время, необходимое на обучение с помощью алгоритмов *SARSA* и Q -обучения (рисунок 2).

Заключение

В процессе выполнения исследований проанализирована работа алгоритмов машинного обучения с подкреплением для безопасного движения при перемещении мобильного робота: *SARSA*, Q -обучение, глубокое Q -обучение и двойное глубокое Q -обучение. Разработано программное обеспечение, проведен вычислительный эксперимент по обучению роботизированной системы.

Результаты анализа показали, что быстрее всего обучается робот при использовании алгоритма *SARSA*, а медленнее всего – алгоритма глубокого Q -обучения. Полученные результаты коррелируют с результатами, представленными в [4], с той лишь разницей, что в работе [4] медленнее всего обучался алгоритм двойного глубокого Q -обучения,

а в данной работе – алгоритм глубокого Q -обучения. Следует отметить, что длина траекторий движения робота для двойного глубокого Q -обучения оказалась наибольшей и составила 21 шаг, а для глубокого Q -обучения – наименьшей, и составила 10 шагов.

В данной работе в предложенном нами алгоритме огибания препятствий отсутствует алгоритм машинного обучения. При использовании данного алгоритма проведен вычислительный эксперимент по огибанию цилиндрических и кубических препятствий. Выявлено, что с использованием данного алгоритма кубические препятствия огибаются быстрее цилиндрических. Оценено время движения до цели с огибанием препятствий в пространстве визуализации *Gazebo 11* (рисунок 1), аналогичное пространство обучения в *Matlab* (рисунок 2). Данное время значительно меньше, чем время, необходимое на обучение с помощью алгоритмов глубокого Q -обучения и двойного глубокого Q -обучения, но больше, чем время, необходимое на обучение с помощью алгоритмов *SARSA* и Q -обучения.

Резюмируя, можно сказать, что верификация нашего алгоритма позволила выявить преимущество нашего алгоритма над алгоритмом машинного обучения с подкреплением в контексте более высокой скорости достижения препятствия по сравнению со скоростью обучения.

ЛИТЕРАТУРА

1. Назарова, А.В. Методы и алгоритмы мультиагентного управления робототехнической системой / А.В. Назарова, Т.П. Рыжова // Вестник МГТУ им. Н. Э. Баумана. Сер. Приборостроение. – 2012. Спец. вып. 6 : Робототехнические системы. – С. 93-105.
2. Fu Yiuwi. Neural Network-Based Learning from Demonstration of an Autonomous Ground Robot / Yiuwi Fu [et al.] // Machines. – 2019. – Vol. 7, № 2. – P. 1-14.

3. **Altuntas N.** Reinforcement learning based mobile robot navigation / N. Altuntas [et al.] // Turkish Journal of electrical engineering & Computer sciences. – 2016. – Vol. 24, № 3. – P. 1747-1767.
4. **Сидоренко, А.В.** Машинное обучение при перемещении мобильного робота / А.В. Сидоренко, Н.А. Солодухо // Компьютерные технологии и анализ данных (CTDA'2022): материалы III Междунар. науч.-практ. конф., Минск, 21–22 апр. 2022 г. / Белорус. гос. ун-т ; редкол.: В. В. Скакун (отв. ред.) [и др.]. – Минск : РИВШ, 2022. – С. 68-72.
5. **Описание пакета Reinforcement Learning Toolbox** [Электронный ресурс]. – Режим доступа: https://www.mathworks.com/help/reinforcement-learning/index.html?s_tid=CRUX_lftnav – Дата доступа: 11.03.2023.
6. **Описание пакета Mobile Robotics Simulation Toolbox** [Электронный ресурс]. – Режим доступа: <https://www.mathworks.com/matlabcentral/fileexchange/66586-mobile-robotics-simulation-toolbox> – Дата доступа: 11.03.2023.
7. **Описание пакета ROS Toolbox** [Электронный ресурс]. – Режим доступа: <https://www.mathworks.com/products/ros.html> – Дата доступа: 11.03.2023.
8. **GitHub** [Электронный ресурс]. – Режим доступа: <https://github.com/MikitaSaladukha/ROSproject> – Дата доступа: 11.03.2023.

REFERENCES

1. **Nazarova, A.V.** Methods and algorithms for multi-agent control of robotic system / A.V. Nazarova, T.P. Ryzhova // Vestnik MGTU im. N.E. Baumana. Ser. Priborostroenie. – 2012. – Spec. iss. 6 : Robototekhnicheskie sistemy. – P. 93-105.
2. **Fu Yiuwi.** Neural Network-Based Learning from Demonstration of an Autonomous Ground Robot / Yiuwi Fu [et al.] // Machines. – 2019. – Vol. 7, № 2. – P. 1-14.
3. **Altuntas N.** Reinforcement learning based mobile robot navigation / N. Altuntas [et al.] // Turkish Journal of electrical engineering & Computer sciences. – 2016. – Vol. 24, № 3. – P. 1747-1767.
4. **Sidorenko, A.V.** Machine learning in mobile robot movement / A.V. Sidorenko, M.A. Saladukha // Computer technology and data analysis (CTDA'2022) : materials of III Intern. sci.-pract. conf., Minsk, 21–22 apr. 2022 y. / Belarusian state university; ed.: V.V. Skakun (main ed.) [et al.]. – Minsk : RIVSH, 2022. – P. 68-72.
5. **Description of Reinforcement Learning Toolbox** [Electronic resource]. – Access: https://www.mathworks.com/help/reinforcement-learning/index.html?s_tid=CRUX_lftnav – Access date: 11.03.2023.
6. **Description of Mobile Robotics Simulation Toolbox** [Electronic resource]. – Access: <https://www.mathworks.com/matlabcentral/fileexchange/66586-mobile-robotics-simulation-toolbox> – Access date: 11.03.2023.
7. **Description of ROS Toolbox** [Electronic resource]. – Access: <https://www.mathworks.com/products/ros.html> – Access date: 11.03.2023.
8. **GitHub** [Electronic resource]. – Access: <https://github.com/MikitaSaladukha/ROSproject> – Access date: 11.03.2023.

SIDORENKO A.V., SALADUKHA N.A.

BENDING OBSTACLES WHEN MOVING A MOBILE ROBOT

*Belarusian State University
Minsk, Republic of Belarus*

The issues of modeling when navigating around obstacles of a mobile robot using machine learning methods are considered: Q-learning, SARSA algorithm, deep Q-learning and double deep Q-learning. The developed software includes the Mobile Robotics Simulation Toolbox, Reinforcement Learning Toolbox, and the Gazebo visualization package for environment simulation. The results of the computational experiment show that for a simulated environment with a size of 17 by 17 cells and an obstacle 12 cells long, training using the SARSA algorithm occurs with better performance than for the others.

An algorithm for avoiding obstacles without the use of machine learning is proposed, and it was shown that the speed of avoiding obstacles using this algorithm is higher than the learning speed using deep Q-learning and double deep Q-learning, but lower than using the SARSA and Q-learning algorithms. . For the proposed algorithm, a numerical experiment was carried out using the robot movement simulation environment in Gazebo II and it was shown that cubic obstacles are being avoided faster than cylindrical ones.

Keywords: robot, machine learning, Q-learning, movement, obstacles.



Сидоренко А.В., профессор факультета радиофизики и компьютерных технологий Белорусского государственного университета, доктор технических наук

E-mail: sidorenkoa@yandex.by



Солодухо Н.А., старший преподаватель факультета радиофизики и компьютерных технологий Белорусского государственного университета, магистр физико-математических наук

ЛОБАТЫЙ А.А., ПЭНХАО ГУ

МАТЕМАТИЧЕСКОЕ МОДЕЛИРОВАНИЕ ДВИЖЕНИЯ ЛЕТАТЕЛЬНЫХ АППАРАТОВ МУЛЬТИРОТОРНОГО ТИПА

Белорусский национальный технический университет
г. Минск, Республика Беларусь

Рассматривается задача определения особенностей и постановки задачи математического моделирования летательных аппаратов (ЛА) мультироторного типа. Рассматриваются отличия их математических моделей от классических математических моделей ЛА самолетного и одновинтового вертолетного типа. Проводится анализ и обоснование действующих на мультироторный ЛА сил и моментов, с учетом особенностей рассмотрения соответствующих систем координат, необходимых для исследования пространственного движения ЛА. Сформулирована задача управления траекторным движением ЛА с учетом вращения его конструкции вокруг центра масс. На основе рассмотрения конструктивной схемы одного из наиболее распространенных четырехвинтового ЛА (квадрокоптера) обоснована схема создания управляющих сил и моментов, действующих на ЛА, под действием которых изменяется траектория движения ЛА в пространстве. Приведены основные математические зависимости, характеризующие кинематику движения ЛА мультироторного типа. На основе проведенного анализа обоснована и приведена обобщенная структурная схема процесса управления таким ЛА. Для проверки работоспособности и адекватности математической модели проведено исследование перемещения квадрокоптера в вертикальной плоскости между заданными точками пространства в соответствии с законом форсированного управления, обеспечивающим перемещение ЛА в пространстве с максимальным быстродействием. Проведенное компьютерное моделирование полученных аналитически математических зависимостей показало, что данный подход применим для построения математических моделей движения ЛА мультироторного типа различной конструктивной компоновки.

Ключевые слова: беспилотный летательный аппарат, квадрокоптер, математическая модель, винт, управляющая сила.

Введение

Летательные аппараты (ЛА) относятся к сложным техническим устройствам, производство, эксплуатация и исследование которых требует создания математических моделей, позволяющих решать задачи анализа и синтеза их подсистем и элементов без проведения натурных испытаний, которые требуют привлечения значительных материальных средств, а иногда и риска для людей. Значение математического моделирования ЛА существенно возросло в связи с широким распространением беспилотных летательных аппаратов (БЛА), у которых на борту отсутствует человек-оператор (пилот), что дает возможность широкого применения достижений науки и техники в конструкции и системах управления БЛА [1, 2].

Вопросы математического моделирования движения ЛА достаточно изучены и исследованы за десятилетия существования данных задач. В основе построения математических моделей полёта ЛА лежат законы кинематики и динамики движения твердого тела атмосфере. Однако, интенсивное развитие современных технологий позволяет конструкторам и инженерам создавать ЛА, которые соединяют в себе такие свойства ЛА, которые ранее считались принципиально противоречивыми и несовместимыми между собой. Это касается в первую очередь достижений в области создания двигателей для ЛА,

построенных на новых физических принципах, а также – автоматических систем управления аэродинамическими силами, создаваемыми различными частями конструкции ЛА, комбинированием различных по природе сил и моментов, действующих на ЛА.

Управление траекторным движением ЛА

В трехмерном пространстве при моделировании движения ЛА необходимо рассматривать несколько систем координат, которые вводятся для того, чтобы решить следующие задачи:

- зафиксировать некоторое начало отсчета, по отношению к которому определяются линейные и угловые координаты ЛА;
- представить наиболее удачным образом составляющие какой-либо внешней силы, момента или элемента движения;
- определить положение некоторых фиксированных направлений, связанных с движущимся телом (ЛА).

В качестве системы координат, в которой определяется положение центра масс ЛА и ориентация его осей, принимается стартовая система координат ($O X_g Y_g Z_g$), начало которой находится в точке старта ЛА, вертикальная ось Z_g направлена нормально к поверхности Земли, ось X_g составляет с осями X_g и Y_g правую систему координат. Направление оси X_g задается и остается неизменным. Эта система

координат жестко связана с Землей и вводится для определения элементов движения ЛА относительно Земли.

С конструкцией ЛА ориентирована связанная (строительная) система координат ($OX_c Y_c Z_c$), положение которой относительно стартовой определяется углами курса ψ , тангажа ν , крена γ . Направление оси X_c привязано, как правило, к продольной оси симметрии ЛА. Оси Y_c и Z_c составляют с осью X_c прямоугольную правую систему координат. Для моделирования движения летательных аппаратов определенной формы и назначения могут вводиться в рассмотрение дополнительно другие системы координат [3], среди которых наиболее распространены следующие:

- скоростная (аэродинамическая) ($OX_v Y_v Z_v$), у которой ось X_v совпадает с вектором скорости ЛА;
- траекторная ($OX_m Y_m Z_m$), у которой продольная ось X_m направлена по вектору скорости ЛА относительно Земли;
- относительная (лучевая) ($OX_u Y_u Z_u$), у которой продольная ось X_u направлена на заданную подвижную точку пространства (цель).

Переход от одной системы координат к другой осуществляется с помощью матриц преобразования (матриц направляющих косинусов). Элементы этих матриц могут определяться различными способами, среди которых основными являются [4]:

- тригонометрический на основе углов Эйлера (Эйлера-Крылова);
- решение матричного дифференциального уравнения Пуассона;
- кватернионный метод, основанный на решении дифференциальных уравнений для параметров Родрига-Гамильтона.

Каждый из этих методов вычисления направляющих косинусов обладает своими достоинствами и недостатками.

Составление математической модели полета ЛА можно разбить на несколько этапов. На первом этапе рассматривается движение ЛА как материальной точки, на которую действуют в пространстве три силы: $\vec{G}$ – вектор силы гравитации, $\vec{R}$ – вектор аэродинамической силы, $\vec{P}$ – вектор силы тяги двигателя. На последующих этапах рассматривается моделирование поступательного и вращательного движения ЛА сложной аэродинамической формы с добавлением математических моделей элементов ЛА, включая математическую модель системы управления.

Гравитационная сила $\vec{G}$ представляет собой потенциал силы тяготения Земли. Её величина зависит от высоты полета ЛА и географического положения ЛА, так как в общем случае форма Земли несколько отличается от шара (сферы). При полете ЛА на большие расстояния следует учитывать кривизну Земли и её вращение.

Взаимодействие поверхности ЛА с набегающим потоком воздуха вызывает аэродинамические силы (подъемную, боковую, сопротивления), равнодействующая которых $\vec{R}$ приложена в точке ЛА, которая называется центром давления [3], в общем случае не совпадающим с центром масс ЛА.

Равнодействующая сил, создаваемых двигателями ЛА (реактивными или винтовыми) представляет собой вектор тяги $\vec{P}$, о котором следует сказать отдельно.

Управление траекторным движением ЛА производится за счет изменения по величине и по направлению сил $\vec{R}$ и $\vec{P}$. Если не рассматривать такие специфические ЛА одноразового применения, как ракеты, снаряды и некоторые другие, то подавляющее большинство ЛА, в том числе и беспилотных (БЛА), можно разделить в зависимости от конструкции и особенностей создания управляющей силы на три группы.

К первой группе следует отнести ЛА самолетной конструктивной схемы, у которых основная составляющая вектора управляющей силы создается путем взаимодействия набегающего потока воздуха с несущей аэродинамической поверхностью ЛА. Такая конструктивная схема является широко распространенной и изученной, так как исторически представляется основной для пилотируемых ЛА. Управление ЛА данной конструкции осуществляется путем изменения вектора $\vec{R}$. Изменение вектора $\vec{P}$ здесь отсутствует или играет вспомогательную роль [5].

Во вторую группу ЛА (БЛА) можно отнести ЛА одновинтовой вертолетной схемы. Такие ЛА оснащены несущим и хвостовым рулевым винтами. В отличие от ЛА самолетной схемы, у которой необходимым условием появления силы $\vec{R}$ является поступательное движение ЛА, у ЛА вертолетной схемы вращающийся несущий винт создает подъемную силу не только при поступательном движении ЛА за счет $\vec{R}$, но и при неподвижном положении в воздухе в режиме висения за счет силы $\vec{P}$, которая уравнивает или превышает гравитационную силу $\vec{G}$ [6].

В отдельную перспективную интенсивно развивающуюся группу ЛА следует отнести ЛА (БЛА) мультироторного типа. Данный тип ЛА имеет несколько двигателей (как правило – винтовых), управление которыми позволяет изменять вектор $\vec{P}$ по величине и направлению. Управление вектором $\vec{R}$ здесь, как правило, не используется, а влияние вектора $\vec{R}$ сказывается на движении ЛА только в виде силы аэродинамического сопротивления.

Могут существовать и другие комбинированные схемы ЛА, например – конвертопланы, у которых на разных режимах полета последовательно преобладают в качестве управляющей силы вектор $\vec{P}$ или $\vec{R}$.

Моделирование движения ЛА мультироторного типа

При составлении математической модели движения ЛА необходимо учитывать его аэродинамическую и конструктивную компоновку. Рассмотрим наиболее распространенную четырехвинтовую схему ЛА мультироторного типа (квадрокоптер) [7, 8], схема которого представлена на рис. 1.




Рисунок 1. Конструктивная схема квадрокоптера

Пусть квадрокоптер имеет четыре винта, расположенные симметрично относительно центра масс конструкции ЛА. Оси связанной (строительной) системы координат, исходя из принципа наглядности, изобразим в виде, представленном на рисунке, привязав к осям симметрии ЛА. Ось Y_1 направлена перпендикулярно осям X_1 и Z_1 вверх. На рис. 1 $M_0, m_1, \dots, m_4$ – массы соответствующих конструктивных частей ЛА, $\omega_1, \dots, \omega_4$ – угловые скорости вращения винтов ЛА.

Угловое положение ЛА относительно инерциальной (стартовой) системы координат задается соответственно углами курса ψ , тангажа ϑ и крена γ . Матрица перехода от связанной к стартовой системе координат (матрица направляющих косинусов) R_c^{-1} вычисляется одним из приведенных выше способов. Поступательное движение центра масс ЛА описывается векторными уравнениями в стартовой системе координат:

$$\dot{S}(t) = V(t), \quad S(t_0) = S_0; \quad (1)$$

$$\dot{V}(t) = a(t), \quad V(t_0) = V_0, \quad (2)$$

где $\dot{S}(t) = [x(t), y(t), z(t)]^T$ – вектор пути (траектория) ЛА, $V(t) = [v_x(t), v_y(t), v_z(t)]^T$ – вектор скорости ЛА, $a(t) = [a_x(t), a_y(t), a_z(t)]^T$ – вектор ускорения центра масс ЛА. Вектор $a(t)$ определяется через измеренные ускорения ЛА в связанной системе координат $a_1(t)$ (показания акселерометров) $a(t) = R_c^{-1}a_1(t)$.

Управляющая движением ЛА равнодействующая сила $\vec{P}$, приложенная в центре масс, и изменяющая траекторию полета, создается вращением винтов ЛА мультироторного типа. На рис. 2 представлена схема создания управляющей силы ЛА в вертикальной плоскости.




Рисунок 2. Схема создания управляющей силы

На рис. 2 обозначено: $\vec{P}_1(\omega_1)$ и $\vec{P}_3(\omega_3)$ – силы тяги, создаваемые соответствующими винтами, имеющими скорости вращения ω_1 и ω_3 (рис. 1), $\vec{P}_x$ и $\vec{P}_y$ – проекции силы $\vec{P}$ на оси инерциальной (стартовой) системы координат. Под действием сил $P_x = P \sin \vartheta$ и $P_y = P \cos \vartheta$ ЛА перемещается горизонтально и вертикально. При этом в состоянии, когда ЛА не перемещается в вертикальном направлении (состоянии висения) сила P_y равна по величине гравитационной силе G . Следовательно, в этом случае $P_y = mg$, где m – масса ЛА, g – гравитационное ускорение на высоте полета ЛА.

В состоянии неподвижного висения:

$$P_y = \sum_{i=1}^n P_i = k \sum_{i=1}^n \omega_i = mg, \quad (3)$$

n – количество винтов ЛА, k – коэффициент пропорциональности, который может быть определен экспериментально. Для ЛА с четырьмя винтами (квадрокоптера) в соответствии с формулой (3)

$$k = \frac{mg}{4\omega_n}, \quad (4)$$

где ω_n – номинальная скорость вращения винтов ЛА, при которой обеспечивается режим висения.

Поворот ЛА на угол ψ (рис. 2) осуществляется за счет разности сил P_1 и P_3 (скоростей ω_1 и ω_3), что создает момент вращения, зависящий также от расстояния между винтами. Вращательное движение ЛА вокруг соответствующей оси связанной системы координат описывается уравнением для углового ускорения. Для каждой из трех i -х осей вращения справедливо известно уравнение механики:

$$\varepsilon_i = \frac{M_i}{J_i}. \quad (5)$$

В формуле (5) ε_i – угловое ускорение, M_i – момент силы, J_i – момент инерции ЛА относительно соответствующей оси. Для тел сложной формы моменты инерции относительно соответствующих осей могут быть определены экспериментально, а для однородных тел простой формы известны.

Например, для шара радиусом r и массой $m J = 0.4mr^2$, тонкая труба или кольцо радиусом r имеет $J = mr^2$, и так далее. В некоторых случаях форма ЛА может считаться состоящей из простых элементов, что облегчает задачу математического моделирования вращательного движения ЛА.

Для перемещения ЛА по заданной (требуемой) траектории $\vec{S}_T(t)$ необходимо синтезировать закон

управления ЛА в виде векторного ускорения центра масс ЛА $\vec{a}_T(t)$ [9]. Изменением величин скоростей вращения винтов ЛА достигается соответствующее значение вектора тяги $\vec{P}(t)$, формирующего фактическую траекторию движения ЛА $\vec{S}_\Phi(t)$. Обобщенная структурная схема процесса управления траекторией движения ЛА представлена на рис. 3.




Рисунок 3. Обобщенная структурная схема процесса управления

В качестве примера рассмотрим перемещение квадрокоптера (БЛА) массой 0.7 кг в вертикальной плоскости на постоянной высоте ($g = 9.81 \text{ кг·м/с}^2$) на расстояние 200 м при номинальной скорости вращения винтов $\omega_n = 340 \text{ рад/с}$. Динамические характеристики вращательного движения БЛА считаем соответствующими характеристикам колебательного звена с постоянной времени $T_n = 0.3$ и коэффициентом затухания $\zeta = 0.7$. Аэродинамическим сопротивлением для наглядности пренебрежем, считая силу $\vec{R}$.

Закон форсированного управления БЛА сформируем на основе метода предложенного в работе [10]. В выражениях (1)-(2) $S(t)$ – расстояние, пройденное БЛА, $V(t)$ – скорость БЛА, $a(t)$ – управляющее ускорение. Необходимо определить управляющее ускорение $a(t)$ при условии, что заданы максимально допустимые значения скорости $V_{\max}$ и ускорения $a_{\max}$ БЛА. В соответствии с [10] выражение для ускорения $a(t)$ имеет вид:

$$a(t) = a_{\max} \text{sign}(\tau - t), \quad (6)$$

где τ – момент переключения релейного управления, t – текущее время.

Если считать, что время полёта БЛА на соответствующих участках траектории S_1, S_2, S_3 будет соответственно T_1, T_2, T_3 , то моменты переключения релейного управления принимают значения $\tau_1 = T_1$, $\tau_2 = T_1 + T_2$, $\tau_3 = T_1 + T_2 + T_3$. В соответствии с законами кинематики равнопеременного движения при $S_0 = 0$ и $V_0 = 0$:

$$S_1 = \frac{a_y T_1^2}{2}, \quad S_2 = V_{\max} T_2, \quad S_3 = V_{\max} T_3 - \frac{a_T T_3^2}{2}, \quad (7)$$

где a_y – максимальное значение ускорения БЛА, a_T – максимальное значение торможения БЛА. Следовательно, с учетом того, что $S = S_1 + S_2 + S_3$ и $V_{\max} = a_{\max} t$ на основании формул (7) получаются значения временных интервалов ускоренного и замедленного движения ЛА:

$$T_1 = \frac{V_{\max}}{a_y}, \quad T_2 = \frac{2Sa_y a_T - V_{\max}^2 (a_y + a_T)}{2V_{\max} a_y a_T}, \quad T_3 = \frac{V_{\max}}{a_T}. \quad (8)$$

На рисунке 4 представлены результаты математического моделирования движения БЛА, полученные в среде *Mathcad*.




Рисунок 4. Результаты моделирования

На рис. 4 обозначено: $v_t(t)$ и $v_\phi(t)$ – требуемый и фактический (изображено пунктиром) угол тангажа БЛА, ω_1 – угловая скорость вращения винта 1 после разворота БЛА на угол v_ϕ в соответствии с рис. 2. $v(t)$ – график изменения скорости движения БЛА, $S(t)$ – график изменения пройденного пути.

Необходимо отметить, что данные результаты моделирования (рис. 4) носят иллюстративный характер, показывая качественное изменение параметров движения центра масс БЛА без учета силы аэродинамического сопротивления, характеристик системы управления и других важных факторов, оказывающих влияние на формирование траектории полета ЛА (БЛА).

Заключение

Математическая модель ЛА мультироторного типа в основе своей представляет собой как и для ЛА других конструктивных схем совокупность кинематических и динамических уравнений

движения твердого тела. Особенностью мультироторных ЛА является существенное преобладание силы тяги двигателей ЛА в создании управляющей силы, изменяющей вектор скорости ЛА, по сравнению с влиянием аэродинамических сил, которые здесь не имеют существенного значения. Следовательно, для математического моделирования ЛА необходимо иметь адекватные математические модели двигателей ЛА. Влияние же на движение ЛА набегающего потока воздуха, как правило, сводится к учету в модели ЛА аэродинамического сопротивления, которое зависит от конкретной конструктивной компоновки ЛА. Всё выше сказанное относится в первую очередь к беспилотным ЛА (БЛА), так как в отличие от пилотируемых ЛА, имеющих ограничения в применении, связанные с физическими возможностями пилота, в БЛА таких ограничений нет, а достижения в области интеллектуальных технологий позволяют иметь на борту БЛА автопилоты, реализующие значительную часть функций человека – пилота.

ЛИТЕРАТУРА

1. Беспилотные летательные аппараты. Основы устройства и функционирования / под ред. И.С. Голубева, И.К. Туркина. – М.: МАИ, 2010. – 654 с.
2. **Беспилотные летательные аппараты** [Электронный ресурс]. Режим доступа: http://geoportal.by/index/bespilotnye_letatelnye_apparaty/0-434/.
3. **Дмитриевский, А.А.** Внешняя баллистика / А.А. Дмитриевский, Л.Н. Лысенко. – М.: Машиностроение, 2005. – 608 с.
4. Современные информационные технологии в задачах навигации и наведения беспилотных маневренных летательных аппаратов / под ред. М.Н. Красильщикова, Г.Г. Серебрякова. – М.: Физматлит, 2009. – 556 с.
5. **Красовский, А.А.** Системы автоматического управления летательных аппаратов / А. А. Красовский, Ю.А. Вавилов, А.И. Сучков. – М.: ВВИА им. Н.Е. Жуковского, 1986. – 477 с.
6. **Моисеев, В.С.** Прикладная теория управления беспилотными летательными аппаратами / В.С. Моисеев. – Казань: ГБУ РЦМКО, 2013. – 768 с.
7. **Гурьянов, А.Е.** Моделирование управления квадрокоптером / А.Е. Гурьянов // Инженерный вестник. – М.: МГТУ им. Н.Э. Баумана. – 2014. – С. 522-534.
8. **Калягин, М.Ю.** Моделирование системы управления полетом квадрокоптера в среде Simulink и Simscape Multibody / М.Ю. Калягин, Д.А. Волошин, А.С. Мазаев // Труды МАИ. Выпуск № 112. Режим доступа: <http://trudymai.ru>
9. **Лобатый, А.А.** Аналитический синтез управляющего ускорения беспилотного летательного аппарата / А.А. Лобатый, А.Ю. Бумай, С.С. Прохорович // Наука и техника. – 2021. – Том 20, № 4. – С. 338-344. DOI: 10.21122/2227-1031-2021-20-4-338-344
10. **Ким, Т.Ю.** Форсированное управление движением мобильного робота / Т.Ю. Ким, Г.А. Прокопович, А.А. Лобатый // Информатика. – 2022. – Том 19, № 3 – С. 86-100.

REFERENCES

1. Unmanned aerial vehicles. Fundamentals of device and functioning / ed. I.S. Golubeva, I.K. Turkina. – M.: MAI, 2010. – 654 p.
2. **Unmanned aerial vehicles** [Electronic resource]. – Access: http://geoportal.by/index/bespilotnye_letatelnye_apparaty/0-434/.
3. **Dmitrievsky, A.A.** External ballistics / A.A. Dmitrievsky, L.N. Lysenko. – M.: Mashinostroenie, 2005. – 608 p.
4. Modern information technologies in the tasks of navigation and guidance of unmanned maneuverable aircraft / ed. M.N. Krasilshchikova, G.G. Serebryakova. – M.: Fizmatlit, 2009. – 556 p.
5. **Krasovsky, A.A.** Systems of automatic control of aircraft / A. A. Krasovsky A. A., Yu. A. Vavilov, A. I. Suchkov. – M.: VVIA im. NOT. Zhukovsky, 1986. – 477 p.
6. **Moiseev, V.S.** Applied control theory for unmanned aerial vehicles / V.S. Moiseev. Kazan: GBU RTSMKO, 2013, 768 p.

7. Guryanov, A.E. Modeling of quadrocopter control / A.E. Guryanov // Engineering Bulletin. – M.: MSTU im. N.E. Bauman, 2014. – Pp. 522-534.
8. Kalyagin, M.Yu. Modeling the flight control system of a quadrocopter in the environment of Simulink and Simscape Multibody / M.Yu. Kalyagin, D.A. Voloshin, A.S. Mazaev // Proceedings of the MAI. Issue No. 112 <http://trudymai.ru>
9. Lobaty, A.A. Analytical synthesis of the control acceleration of an unmanned aerial vehicle / A.A. Lobaty, A.Yu. Bumai, S.S. Prokhorovich // Science and technology, 2021. – Vol. 20, no. 4. – Pp. 338-344. DOI: 10.21122/2227-1031-2021-20-4-338-344
10. Kim, T.Yu. Forced motion control of a mobile robot / T.Yu. Kim, G.A. Prokopovich, A.A. Lobaty // Informatics, 2022. – Vol. 19, no. 3. – Pp. 86-100.

LOBATY A.A., GU PENGHAO

MATHEMATICAL MODELING OF MOVEMENT OF MULTI-ROTOR TYPE AIRCRAFT

Belarusian National Technical University
Minsk, Republic of Belarus

The problem of determining the features and setting the problem of mathematical modeling of multirotor aircraft (LA) is considered. Differences of their mathematical models from the classical mathematical models of aircraft and single-rotor helicopter type aircraft are considered. The analysis and substantiation of the forces and moments acting on a multirotor aircraft are carried out, taking into account the peculiarities of considering the corresponding coordinate systems necessary for studying the spatial motion of the aircraft. The problem of controlling the trajectory motion of an aircraft is formulated taking into account the rotation of its structure around the center of mass. Based on the consideration of the structural diagram of one of the most common four-rotor aircraft (quadcopter), a scheme for creating control forces and moments acting on the aircraft, under the influence of which the aircraft's trajectory in space changes, is substantiated. The main mathematical dependences characterizing the kinematics of the motion of a multi-rotor aircraft are given. On the basis of the analysis carried out, a generalized block diagram of the control process for such an aircraft is substantiated and presented. To test the performance and adequacy of the mathematical model, a study was made of the movement of a quadrocopter in a vertical plane between given points in space in accordance with the law of forced control, which ensures the movement of an aircraft in space with maximum speed. The computer simulation of the obtained analytically mathematical dependences showed that this approach is applicable to the construction of mathematical models of the motion of multirotor type aircraft of various design layouts.


Keywords: *unmanned aerial vehicle, quadrocopter, mathematical model, propeller, control force.*



Лобатый Александр Александрович, доктор технических наук, профессор. Проводит исследования в области анализа и синтеза систем управления, в том числе - беспилотными летательными аппаратами. Автор и соавтор множества статей в научных журналах и конференциях, автор ряда книг и учебных пособий.

Lobaty A.A., Doctor of Science, Professor. Conducts research in the areas of analysis and synthesis of control systems including unmanned aerial vehicles. He is the author and co-author of many articles in scientific journals, conferences and books.

E-mail: lobaty@bntu.by



Гу Пэнхао, аспирант кафедры «Робототехнические системы» Белорусского национального технического университета. Проводит исследования в области анализа и синтеза систем управления применительно к беспилотным летательным аппаратам.

Gu Penghao, post-graduate student of the Department of Robotic Systems, Belarusian National Technical University. Conducts research in the field of analysis and synthesis of stochastic control systems in relation to unmanned aerial vehicles.

E-mail: rts@bntu.by

ШЕЙНИКОВ А.А., ИВАНИЦКИЙ Л.А., МАЛКИН В.А.

АНАЛИЗ ПОГРЕШНОСТЕЙ ДАТЧИКА АВИАГОРИЗОНТА НА БАЗЕ СИСТЕМЫ ТЕХНИЧЕСКОГО ЗРЕНИЯ

УО «Военная академия Республики Беларусь»
г. Минск, Республика Беларусь

Рассматривается задача определения особенностей и постановки задачи математического моделирования в статье рассматриваются особенности практической реализации датчика авиагоризонта на базе бортовой системы технического зрения. Предложен, разработанный на базе известных приложений, вариант алгоритма работы видеосистемы ориентации беспилотного летательного аппарата. Показаны проблемы автоматического обнаружения и определения положения линии горизонта на сменяющихся цифровых изображениях, составляющих видеопоток от бортовой цифровой камеры. Проведен анализ факторов, влияющих на точность оценки углов ориентации носителя с использованием предлагаемой системы. Приведены результаты практического исследования, характеризующие степень влияния рассматриваемых факторов на общую погрешность. Разработана дискретная стохастическая математическая модель системы ориентации беспилотного летательного аппарата на базе бортовой системы технического зрения. Показана возможность обеспечения приемлемого уровня точности видеосистемы ориентации за счет определенных технических и алгоритмических решений. Сделан вывод о целесообразности применения этой системы в автономных мультисенсорных навигационных комплексах беспилотных летательных аппаратов.

Ключевые слова: датчик авиагоризонта, система технического зрения, погрешность измерения углов ориентации, дискретная стохастическая математическая модель.

Введение

В настоящее время бортовая цифровая камера (БЦК) является обязательным элементом оборудования любого, даже самого дешевого, беспилотного летательного аппарата (БЛА). Во многих БЛА более высокого ценового сегмента, в состав бортового оборудования входит не просто БЦК, а система технического зрения (СТЗ), включающая БЦК (в общем случае систему из нескольких БЦК, работающих в одинаковых или различных диапазонах длин волн), вычислитель и программно-алгоритмическое обеспечение обработки видовой информации. По своей сути БЦК является датчиком геофизического поля (оптического или теплового). Соответственно, с учетом современного развития технологий, СТЗ может рассматриваться как перспективная автономная система автоматической навигации по геофизическим полям [1]. Так, при наличии специального алгоритмического обеспечения и достаточных вычислительных ресурсов, СТЗ с БЦК оптического диапазона может реализовывать те же функции, что и бесплатформенная инерциальная навигационная система (БИНС) (являющаяся основой большинства современных систем и комплексов воздушной навигации): счисление углов ориентации, скоростных параметров, координат БЛА (с использованием алгоритмов вычисления оптического потока) [2]. Причем, для многих малоразмерных тактических (МТ) БЛА характерно жесткое закрепление БЦК в корпусе носителя, что обуславливает соответствие его динамики и эволюций датчика изображений (светочувствитель-

ной матрицы (СЧМ) БЦК), которые можно описать методами проективной геометрии [3]. Известным недостатком методов счисления пилотажно-навигационных параметров полета (ПНПП) является интегральное накопление ошибок с течением времени, что обусловлено наличием погрешностей у любого датчика, существующих на каждом шаге измерения. Поэтому, разработчики стараются дополнительно применять альтернативные методы оценки ПНПП, опирающиеся на неизменную по времени (медленно меняющуюся по известному закону) внешнюю информацию об окружающем пространстве и его свойствах. В этом случае удастся решить проблему с неограниченным ростом ошибок оценивания ПНПП (путем периодической коррекции последних), но встает проблема уменьшения, хоть и стабильных, но существенных, систематических и случайных погрешностей соответствующих датчиков (магнитометрических и пирометрических систем ориентации [4], магнитометрических систем глобального позиционирования [5] и астронавигационных систем [6]). Так, с учетом специфики работы СТЗ, измерение углов ориентации (крена и тангажа) БЛА можно производить опираясь на информацию о положении линии горизонта (ЛГ) [7]. При этом процесс распознавания линии, разделяющей области неба и земной поверхности на цифровом изображении (ЦИ), является ключевым во всей системе [8]. Он сопряжен со многими трудностями, преодолеть которые полностью невозможно. Однако повышение эффективности алгоритмов обработки ЦИ позволяет снизить

погрешности измерения углов ориентации ($\Delta_{\text{уго}}$) и запаздывание навигационных решений (повысить частоту выдачи информации $n_{\text{БИ}}$) до приемлемого уровня ($\Delta_{\text{уго}} \leq 1,5^\circ$, $n_{\text{БИ}} \geq 60$ Гц) [8]. Учитывая перечисленные особенности функционирования системы ориентации БЛА на базе СТЗ (СОСТЗ), в процессе теоретических исследований ее целесообразно представлять в виде дискретной стохастической измерительной системы [9]. Следует также учитывать, что реализация потенциала СОСТЗ по точности возможна в случае комплексирования с другими бортовыми автономными датчиками ПНИ, работающими на других физических принципах и также представляющими собой дискретные стохастические измерительные системы [10]. Соответственно, при анализе рассматриваемого датчика ПНИ для целей последующего синтеза автономного мультисенсорного навигационного комплекса (МСНК) БЛА, целесообразно использовать дискретную стохастическую математическую модель (ДСММ) СОСТЗ. Основными факторами, влияющими на точность СОСТЗ являются: погрешности БЦК как средства измерения (погрешность квантования, зависящая от размера пикселя СЧМ и фокусного расстояния [11]), наличие преград на местности (высотные объекты естественного или искусственного происхождения) и в небе (облака, дым и др.), частично загромождающих ЛГ (что обуславливает погрешность аппроксимации ЛГ), засветка и зашумление ЦИ, обусловленные факторами окружающей среды (солнечная активность, погодные условия). Кроме этого, особенности функционирования СОСТЗ могут обуславливать ограничения на максимальные углы ориентации и высоту полета МТБЛА.

Постановка задачи

Определить максимальный диапазон измерений углов ориентации БЛА с учетом особенностей функционирования СОСТЗ. Провести анализ влияния основных факторов на точность измерений углов ориентации БЛА с помощью СОСТЗ. Разработать ДСММ СОСТЗ. Оценить возможность применения СОСТЗ в МСНК МТБЛА.

Начальные условия для решения задачи: в качестве носителя выбран МТБЛА типа квадрокоптер; СОСТЗ состоит из вычислителя (с установленным программно-алгоритмическим обеспечением обработки видовой информации) и БЦК оптического диапазона, установленной по курсу и жестко связанной с корпусом БЛА.

Решение задачи

На ЦИ, полученных с помощью БЦК, область неба является относительно однородной и светлой, а область земли, представляет собой смесь цветов, форм и т.п., в среднем имеющую более темный оттенок. С математической точки зрения, область неба на

ЦИ имеет меньшую дисперсию цвета (меньшую дисперсию оттенков серого полутонового ЦИ) и большее значение средней яркости точек по сравнению с областью земной поверхности. Граница перехода между этими областями и есть искомая ЛГ.

Предлагается следующий алгоритм работы СОСТЗ:

1. Получение ЦИ из видеопотока от БЦК.
2. Перевод ЦИ из цветового пространства *RGB* (трехканальная цветовая модель *red*, *green*, *blue* – красный, зеленый, синий) в полутоновое (выполненное в градациях серого цвета) [12]. Этот этап предварительной обработки ЦИ, предназначен для упрощения вычислений за счет исключения из анализа информации о цветовых характеристиках элементов ЦИ (цветовой тон, насыщенность – многопараметрическая система) и перехода к анализу яркостной информации (однопараметрическая система).
3. Последовательное применение центрированной гауссовой функции (размытие по Гауссу) и медианного фильтра [13]. Этот этап предварительной обработки ЦИ предназначен для улучшения структуры ЦИ за счет подавления высокочастотных компонентов при сохранении без искажений резких границ объектов (рисунок 1, а).
4. Применение фильтра Лапласа для выделения границ [14]. В процессе этого этапа обработки ЦИ подчеркиваются разрывы уровней яркости на ЦИ и подавляются области с относительно плавным изменением яркости. После использования фильтра Лапласа на ЦИ остаются две глобальных однородных, но отличающихся по яркости области (область неба и область земли), имеющие общую границу.
5. Вычисление порога по методу Отсу и преобразование полутонового ЦИ в бинарное (черно-белое) (рисунок 1, б) [14].
6. Поиск точек ЦИ, лежащих на переходе между черной и белой областями ЦИ [14]. В процессе этого этапа обработки ЦИ формируется набор точек, составляющих линию перехода (в естественных условиях обычно ломаную как на рисунке 1, б).
7. Сглаживание набора полученных точек (составляющих искомую ЛГ) прямой линией с помощью метода наименьших квадратов (МНК) [15].
8. Определение угла крена γ (в градусах) по формуле [8]:

$$\gamma = \frac{180}{\pi} \arctg\left(\frac{l_1 - l_2}{X}\right), \quad (1)$$

где l_1 , l_2 , X – геометрические параметры областей ЦИ в пикселях (рисунок 2).

Шаг 8. Определение угла тангажа ϑ (в градусах) с учетом вертикального смещения ЛГ в поле зрения БЦК по формуле [8]:

$$\vartheta = \frac{180}{\pi} (2 \arctg\left(\frac{b}{Y} \tg \omega\right) - \arccos\left(\frac{R}{R+h}\right)), \quad (2)$$

где b – вертикальное смещение ЛГ на ЦИ (рисунок 3), ω – поле зрения БЦК, соответствующее стороне Y (в пикселях) СЧМ БЦК (рисунок 3), R – радиус поверхности Земли, аппроксимированной сферой; h – истинная высота полета БЛА.

Разработчики стремятся обеспечить высокое значение максимальной высоты полета БЛА. С другой

стороны, для СОСТЗ критически важным является наличие видимости ЛГ. В качестве основного препятствия при этом выступает облачность. В связи с тем, что нижнее основание облаков обычно не опускается ниже 600 м [16], в качестве «потолка» для БЛА, оснащенного СОСТЗ, целесообразно принять это значение.



а



б

Рисунок 1. Преобразование полутонового ЦИ в бинарное




Рисунок 2. Параметры областей ЦИ, необходимые для определения угла крена




Рисунок 3. Параметры областей ЦИ, необходимые для определения угла тангажа

Ограничения по углу крена (при $\vartheta = 0^\circ$) связаны с выходом аппроксимированной ЛГ за верхнюю (нижнюю) «рамку» ЦИ ($l_1 = 0$, $l_2 = Y$ или $l_1 = Y$, $l_2 = 0$). Тогда, с учетом принятого допуска в 5 % (размера «буферной зоны»), предельное значение измеряемого угла крена для конкретной БЦК можно рассчитать следующим образом:

$$\gamma_{\text{дон}} = \frac{180}{\pi} \arctg\left(\pm \frac{0,9Y}{X}\right). \quad (3)$$

По углу тангажа также имеются ограничения, связанные с невозможностью обеспечения присутствия ЛГ в кадре при малых высотах полета и малом поле зрения БЦК (с учетом «буферной зоны»):

$$\vartheta_{\text{дон}} = \frac{180}{\pi} (2 \arctg(0,45 \tan \omega) - \arccos(\frac{6371}{6371+h})). \quad (4)$$

При проведении исследований использовалась цифровая камера *Defender C-2525HD* (таблица 1).

Таблица 1

Характеристики цифровой камеры *Defender C-2525HD* в режиме видео

Цена, USD	Эффективное фокусное расстояние объектива, мм	Разрешение видео, пикселей	Поле зрения, град.
20	4,8-8,0	640x480	57,8-36,7

Для выбранной БЦК были рассчитаны предельные значения измеряемых параметров: $\gamma_{\text{дон}} \approx \pm 35^\circ$ (при $\vartheta = 0^\circ$) (рисунок 4, а), $\vartheta_{\text{дон}} \approx \pm 50^\circ$ (при $\gamma = 0^\circ$, $h = 40$ м) (рисунок 4, б). Расширение диапазона измеряемых углов ориентации носителя СОСТЗ возможно за счет обеспечения $Y = \max$. С другой стороны, для увеличения скорости


обработки ЦИ (с целью обеспечения работы СОСТЗ в режиме реального времени) целесообразно обеспечить $XY = \min$ при условии сохранения приемлемого уровня точности измерений ($\Delta\gamma_{\text{max}} = \Delta\vartheta_{\text{max}} = 1,5^\circ$ [8]).

Алгоритм СОСТЗ предполагает автоматическое сглаживание ЛГ по МНК:


$$\begin{cases} y = \frac{K_{xy}^*}{D_x^*} x + m_y^* - \frac{K_{xy}^*}{D_x^*} m_x^* \\ m_x^* = \frac{\sum_{i=1}^n x_i}{n}; m_y^* = \frac{\sum_{i=1}^n y_i}{n}; K_{xy}^* = \frac{\sum_{i=1}^n (x_i - m_x^*)(y_i - m_y^*)}{n}; D_x^* = \frac{\sum_{i=1}^n (x_i - m_x^*)^2}{n} \end{cases} \quad (5)$$

где x, y – координаты точки ЦИ, лежащей на линии перехода между белой и черной областями; $i = 1, 2, 3, \dots, n$ – количество анализируемых точек ЦИ; K_{xy}^* – корре-

ляционный момент; m_x^*, m_y^* – математические ожидания координат анализируемых точек; D_x^* – дисперсия значений координат анализируемых точек по оси X ЦИ.



а



б

Рисунок 4. Результат работы СОСТЗ при предельных значениях углов ориентации

Для оценки влияния погрешности алгоритмической аппроксимации ЛГ на точность определения вертикали (Δg_{xy}) были выбраны следующие начальные условия: $\gamma = 0^\circ$, $X = [600...2880]nkc$, $\Delta Y_{ЛГ} = [2...10]nkc$ ($\Delta Y_{ЛГ}$ – заданное значение СКО вертикального случайного разброса точек, составляющих ЛГ на ЦИ). Результаты моделирования (рисунок 5) показывают, что

при увеличении ΔY растет погрешность оценки крена $\Delta \gamma$. Так, при $\Delta Y = 2nkc - \Delta \gamma = 0,6^\circ$ (линия 3), при $\Delta Y = 5nkc - \Delta \gamma = 2^\circ$ (линия 2), $\Delta Y = 10nkc - \Delta \gamma = 7^\circ$ (линия 1). Увеличение X (при $\Delta Y = \text{const}$) положительно влияет на точность определения вертикали. Так, при $X = 600nkc - \Delta \gamma = 2^\circ$ (линия 5), при $X = 2880nkc - \Delta \gamma = 0,5^\circ$ (линия 4).




Рисунок 5. Результаты алгоритмического сглаживания ЛГ на ЦИ

Результаты анализа показывают принципиальную возможность стабилизации Δg_{xy} в пределах $\pm 4^\circ$ за счет обеспечения $X = \max$. С учетом предыдущих выводов ($Y = \max$, $XY = \min$), очевидной становится необходимость поиска вариантов, обеспечивающих оптимальное соотношение X и Y .

Для оценки влияния факторов окружающей среды на точность автоматического определения линии горизонта (Δg_{noise}) были выбраны следующие начальные условия: $\gamma = 0^\circ$, $\vartheta = 0^\circ$, $h = 40$ м, $X = 640nkc$, $Y = 480nkc$. В процессе исследований производились преобразования ЦИ: яркость исходного ЦИ принималась равной 50 % и изменялась с шагом 10 % в диапазоне [10 %...90 %]; изменялась степень зашумления ЦИ путем автоматического увеличения локальной дисперсии шума для каждого пикселя на 20 единиц (процесс добавления импульсного шума к ЦИ состоит в замене исходных значений яркости пикселей на новые случайные значения (в пределах заданного СКО) [14]; значение заданного угла крена $\gamma_{зад}$ изменялось в диапазоне $[-35^\circ...35^\circ]$ с шагом 5° ; значение заданного угла тангажа $\vartheta_{зад}$ изменялось в диапазоне $[-35^\circ...35^\circ]$ с шагом 3° . Разность между заданными и расчетными (вычисленными СОСТЗ) значениями углов ориентации ($\Delta \gamma = \gamma_{зад} - \gamma_{расч}$, $\Delta \vartheta = \vartheta_{зад} - \vartheta_{расч}$) рассматривалась как погрешность,

возникающая из-за ошибок автоматического определения ЛГ на ЦИ (таблица 2). Анализ таблицы 2 показывает, что: изменение яркости ЦИ в заданных пределах не вызывает существенного изменения погрешности определения углов ориентации БЛА; заданное увеличение степени зашумления ЦИ приводит к существенному росту погрешности определения углов ориентации (в 1,5 раза). Результаты анализа показывают принципиальную возможность стабилизации Δg_{noise} в пределах $\pm 0,3^\circ$ за счет применения эффективных алгоритмов предварительной обработки ЦИ (например, совместное применение медианного фильтра и размытия по Гауссу).

Оценку погрешностей определения вертикали, обусловленных инструментальными погрешностями (погрешность квантования) бортовой оптико-электронной измерительной системы (Δg_q) можно провести, основываясь на результатах, полученных в предыдущей работе авторов [17]. Результаты анализа показывают принципиальную возможность стабилизации Δg_q в пределах $\pm 0,05^\circ$ за счет применения СЧМ БЦК с меньшим размером пикселей.

Таким образом, ДСММ СОСТЗ в общем случае может быть описана следующим образом:

$$z_k = j \cdot \left(g_k + \Delta g_k^{xy} \xi_k^{xy} + \Delta g_k^{noise} \xi_k^{noise} + \Delta g_k^q \xi_k^q \right), \quad j = \begin{cases} 1, & \text{при } \gamma \leq \gamma_{дон} (\vartheta \leq \vartheta_{дон}) \\ \text{error}, & \text{при } \gamma > \gamma_{дон} (\vartheta > \vartheta_{дон}) \end{cases} \quad (6)$$

где j – параметр, учитывающий ограничения по углам ориентации БЛА, z_k – результат измерения ориентации БЛА с помощью СОСТЗ на k -м шаге; g_k – истинное угловое положение БЛА; ξ_k^{xy} , ξ_k^{noise} , ξ_k^q – шумы измерений, обусловленные погрешностью

алгоритмической аппроксимации ЛГ, негативным влиянием факторов окружающей среды и инструментальными погрешностями СОСТЗ. Все перечисленные шумы являются независимыми дискретными гауссовскими белыми шумами с нулевым средним и единичной дисперсией.

Таблица 2

Влияние яркости и степени зашумления ЦИ на точность СОСТЗ

Амплитуда шума 0 ед.									
Яркость, %	10	20	30	40	50	60	70	80	90
$\gamma_{зад}$, град	-20	-15	-10	-5	0	5	10	15	20
$\gamma_{расч}$, град	-19,61	-14,70	-9,75	-4,63	0,23	5,27	10,22	15,14	20,09
$\Delta\gamma$, град	0,39	0,3	0,25	0,37	0,23	0,27	0,22	0,14	0,09
$\vartheta_{зад}$, град	-15	-12	-9	-3	0	3	9	12	15
$\vartheta_{расч}$, град	-15,34	-11,75	-8,57	-2,32	-0,83	3,50	9,85	12,78	15,83
$\Delta\vartheta$, град	-0,34	0,25	0,43	0,68	-0,83	0,5	0,85	0,78	0,13
Амплитуда шума 20 ед.									
Яркость, %	10	20	30	40	50	60	70	80	90
$\gamma_{зад}$, град	-20	-15	-10	-5	0	5	10	15	20
$\gamma_{расч}$, град	-19,54	-14,62	-9,68	-4,57	0,59	5,19	10,29	15,37	20,12
$\Delta\gamma$, град	0,46	0,38	0,32	0,43	0,59	0,19	0,29	0,37	0,12
$\vartheta_{зад}$, град	-15	-12	-9	-3	0	3	9	12	15
$\vartheta_{расч}$, град	-15,83	-11,54	-9,51	-2,18	-1,05	3,86	8,31	12,78	16,25
$\Delta\vartheta$, град	-0,83	0,46	-0,51	0,82	-1,05	0,86	-0,69	0,78	1,25

Результаты моделирования с использованием разработанной ДСММ показывают возможность обеспечения стабилизации общей погрешности СОСТЗ в пределах $\pm 0,75^\circ$ (что удовлетворяет приемлемому уровню точности измерений углов ориентации БЛА). Наибольший вклад в общую погрешность СОСТЗ вносят погрешности алгоритмической аппроксимации ЛГ (53 % от общей погрешности).

Заключение

Таким образом, в процессе исследований

разработана ДСММ СОСТЗ, отличающаяся учетом ограничений на максимальные углы ориентации носителя и учетом влияния основных факторов на точность измерения углов ориентации БЛА, что позволяет выявить эффективные направления совершенствования СОСТЗ.

Общая погрешность СОСТЗ сравнима с погрешностью БИНС, что делает целесообразным совместное использование рассматриваемых систем (работающих на различных физических принципах) в автономных МСНК БЛА.

ЛИТЕРАТУРА

1. Белоглазов, И.Н. Основы навигации по геофизическим полям / И.Н. Белоглазов. – М.: Наука, 1985. – 328 с.
2. Шейников, А.А. Оценка пилотажно-навигационных параметров полета БЛА с учетом результатов обработки последовательности изображений / А.А. Шейников, А.М. Коваленко // ГУ НИИ ВС РФ «Наука и военная безопасность». – 2021. – № 2(68). – С. 98-107.
3. Клетте, Р. Компьютерное зрение. Теория и алгоритмы / Р. Клетте. пер. с англ. А.А. Слинкин. – М.: ДМК Пресс, 2019. – 506 с.
4. Распопов, В.Я. Микросистемная авионика. – Тула: Гриф и К, 2010. – 248 с.
5. Canciani, A.J. Absolute positioning using the Earth's magnetic anomaly field: diss. ... PhD: AFIT-ENG-DS-16-S-074 / Aaron J. Canciani. – Ohio, 2016. – 264 p.
6. Воробьев, Л.М. Астрономическая навигация летательных аппаратов / Л.М. Воробьев. – М.: Машиностроение, 1968. – 281 с.
7. Костяшкин, Л.Н. Обработка изображений в авиационных системах технического зрения / Л.Н. Костяшкин, М.Б. Никифоров. – М.: ФИЗМАТЛИТ, 2016. – 240 с.
8. Распопов, В.Я. Микросистемы ориентации беспилотных летательных аппаратов / В.Я. Распопов. – М.: Машиностроение, 2011. – 184 с.
9. Красильщиков, М.Н. Современные информационные технологии в задачах навигации и наведения беспилотных маневренных летательных аппаратов / М.Н. Красильщиков, Г.Г. Серебряков. – М.: ФИЗМАТЛИТ, 2009. – 556 с.

10. **Матвеев, В.В.** Основы построения бесплатформенных инерциальных навигационных систем / В.В. Матвеев, В.Я. Распопов. – СПб.: ГНЦ РФ ОАО «Концерн «ЦНИИ «Электроприбор», 2009. – 280 с.
11. **Удалов, Н.В.** Методы и алгоритмы обработки цифровых изображений в комплексных системах наблюдения летательных аппаратов / Н.В. Удалов. – М.: Изд-во МАИ, 2014. – 144 с.
12. **Гонсалес, Р.С.** Цифровая обработка изображений / Р.С. Гонсалес, Вудс Р.Е. пер. с англ. П.А. Чочиа. – М.: Техносфера, 2012. – 1104 с.
13. **Фисенко, В.Т.** Компьютерная обработка и распознавание изображений / В.Т. Фисенко, Т.Ю. Фисенко. – СПб.: СПбГУ ИТМО, 2008. – 192 с.
14. **Старовойтов, В.В.** Цифровые изображения: от получения до обработки / В.В. Старовойтов, Ю.И. Голуб. – Минск: ОИПИ НАН Беларуси, 2014. – 202 с.
15. **Вентцель, Е.С.** Теория вероятностей / Е.С. Вентцель. – М.: Высшая школа, 2006. – 575 с.
16. **Богаткин, О.Г.** Авиационная метеорология / О.Г. Богаткин. – СПб.: Изд-во РГГМУ, 2005. – 328 с.
17. **Шейников, А.А.** Математическая модель ошибок высотомера беспилотного летательного аппарата на базе стереосистемы технического зрения / А.А. Шейников, В.А. Малкин, А.А. Санько, Л.А. Иваницкий // Авиационный вестник. – 2022. – № 7. – С. 69-75.

REFERENCES

1. **Beloglazov, I.N.** Fundamentals of navigation in geophysical fields / I.N. Beloglazov. – M.: Nauka, 1985. – 328 p.
2. **Sheinikov, A.A.** Evaluation of flight and navigation parameters of the UAV flight, taking into account the results of image sequence processing / A.A. Sheinikov, A.M. Kovalenko // State Research Institute of the Armed Forces of the Republic of Belarus «Science and military security». – 2021. – No. 2 (68). – P. 98-107.
3. **Klette, R.** Computer vision. Theory and algorithms / R. Klette. per. from English. A.A. Slinkin. – M.: DMK Press, 2019. – 506 p.
4. **Raspopov, V.Ya.** Microsystem avionics. – Tula: Grif and K, 2010. – 248 p.
5. **Canciani, A.J.** Absolute positioning using the Earth's magnetic anomaly field: diss. ... PhD: AFIT-ENG-DS-16-S-074 / Aaron J. Canciani. – Ohio, 2016. – 264 p.
6. **Vorobyov, L.M.** Astronomical navigation of aircraft / L.M. Vorobyov. – M.: Mashinostroenie, 1968. – 281 p.
7. **Kostyashkin, L.N.** Image processing in aircraft vision systems / L.N. Kostyashkin, M.B. Nikiforov. – M.: FIZMATLIT, 2016. – 240 p.
8. **Raspopov, V.Ya.** Microsystems for orientation of unmanned aerial vehicles / V.Ya. Raspopov. – M.: Mashinostroenie, 2011. – 184 p.
9. **Krasilshchikov, M.N.** Modern information technologies in the tasks of navigation and guidance of unmanned maneuverable aircraft / M.N. Krasilshchikov, G.G. Serebryakov. – M.: FIZMATLIT, 2009. – 556 p.
10. **Matveev, V.V.** Fundamentals of construction of strapdown inertial navigation systems / V.V. Matveev, V.Ya. Raspopov. – St. Petersburg: State Scientific Center of the Russian Federation OJSC «Concern» Central Research Institute «Elektroprigor», 2009. – 280 p.
11. **Udalov, N.V.** Methods and algorithms for processing digital images in complex systems for observing aircraft / N.V. Udalov. – M.: Publishing House of MAI, 2014. – 144 p.
12. **Gonzalez, R.S.** Digital image processing / R.S. Gonzalez, Woods R.E. per. from English. P.A. Chochia. – M.: Technosfera, 2012. – 1104 p.
13. **Fisenko, V.T.** Computer processing and image recognition / V.T. Fisenko, T.Yu. Fisenko. – St. Petersburg: St. Petersburg State University ITMO, 2008. – 192 p.
14. **Starovoitov, V.V.** Digital images: from acquisition to processing / V.V. Starovoitov, Yu.I. Golub. – Minsk: OIPI NAS of Belarus, 2014. – 202 p.
15. **Wentzel, E.S.** Probability theory / E.S. Wentzel. – M.: Higher school, 2006. – 575 p.
16. **Bogatkin, O.G.** Aviation meteorology / O.G. Bogatkin. – St. Petersburg: Publishing House of the Russian State Humanitarian University, 2005. – 328 p.
17. **Sheinikov, A.A.** Mathematical model of errors in the altimeter of an unmanned aerial vehicle based on a stereo vision system / A.A. Sheinikov, V.A. Malkin, A.A. Sanko, L.A. Ivanitsky // Aviation Bulletin. – 2022. – No. 7. – Pp. 69-75.

SHEINIKOV A.A., IVANITSKI L.A., MALKIN V.A.

ANALYSIS OF ERRORS OF THE ARTIFICIAL HORIZON SENSOR BASED ON VISION SYSTEM

*Military academy of the Republic of Belarus
Minsk, Republic of Belarus*

The article discusses the features of the practical implementation of the artificial horizon sensor based on the onboard vision system. Proposed, developed on the basis of well-known applications, a variant of the algorithm for the operation of an unmanned aerial vehicle orientation video system. The problems of automatic detection and determination of the position of the horizon line on changing digital images that make up the video stream from the onboard digital camera are shown. The analysis of the factors influencing the accuracy of estimation of carrier orientation angles using the proposed system is carried out. The results of a practical study are presented, characterizing the degree of influence of the considered factors on the total error. A discrete stochastic mathematical model of an unmanned aerial vehicle orientation system based on an onboard vision system has been developed. The possibility of providing an acceptable level of accuracy of the orientation video system due to certain technical and algorithmic solutions is shown. The conclusion is made about the expediency of using this system in autonomous multisensor navigation systems for unmanned aerial vehicles.

Keywords: artificial horizon sensor; vision system; orientation angle measurement error; discrete stochastic mathematical model.



Шейников Алексей Александрович, кандидат технических наук, доцент, докторант учреждения образования «Военная академия Республики Беларусь». Область научных интересов – методы анализа и синтеза навигационных комплексов беспилотных летательных аппаратов

Sheinikau Aliaksei, candidate of technical sciences, associate professor, doctoral student of the educational institution “Military academy of the Republic of Belarus”. Area of scientific interests methods of analysis and synthesis of unmanned aerial vehicles navigation systems.

E-mail: af.varb.ao@gmail.com



Иваницкий Леонид Александрович, адъюнкт учреждения образования «Военная академия Республики Беларусь». Область научных интересов – методы анализа и синтеза навигационных комплексов беспилотных летательных аппаратов.

Ivanitski Leanid, graduate student of the educational institution “Military academy of the Republic of Belarus”. Area of scientific interests methods of analysis and synthesis of unmanned aerial vehicles navigation systems.

E-mail: leonid210785@mail.ru



Малкин Виталий Александрович, доктор технических наук, профессор, профессор кафедры авиационных радиоэлектронных систем авиационного факультета учреждения образования «Военная академия Республики Беларусь». Область научных интересов – методы анализа и синтеза систем автоматического управления летательных аппаратов.

Malkin Vitaliy, doctor of technical sciences, professor, professor of the department of aviation radio-electronic systems of the aviation faculty of the educational institution “Military academy of the Republic of Belarus”. Area of scientific interests methods of analysis and synthesis of aircraft automatic control systems

**ОБРАБОТКА
ИНФОРМАЦИИ
И ПРИНЯТИЕ РЕШЕНИЙ**

**DATA PROCESSING
AND
DECISION-MAKING**

ЛУКАШЕВИЧ М.М.

НЕЙРОСЕТЕВОЙ КЛАССИФИКАТОР ДЛЯ ОПРЕДЕЛЕНИЯ ДИАБЕТИЧЕСКОЙ РЕТИНОПАТИИ ПО ИЗОБРАЖЕНИЯМ СЕТЧАТКИ

УО «Белорусский государственный университет информатики и радиоэлектроники»
г. Минск, Республика Беларусь

С распространением сахарного диабета диабетическая ретинопатия (ДР) становится основной проблемой здравоохранения (особенно в развивающихся странах). Долгосрочные осложнения, возникающие в результате ДР, оказывают значительное влияние на пациентов. Ранняя диагностика и последующее лечение могут уменьшить наносимый здоровью вред. Предсказательная аналитика может быть основой для анализа изображений сетчатки глаза человека с помощью сверточных нейронных сетей. В работе исследования сосредоточены на разработке эффективного метода определения ДР на основе сверточной нейронной сети EfficientNet, технологии самообучения и операций аугментации данных. В результате экспериментов разработан нейросетевой классификатор на основе сверточных нейросетей, даны рекомендации для проведения аугментации данных. Эксперименты выполнены на публичном наборе данных и показали, что возможно достичь доли правильно классифицированных объектов равной 97,14 % на тестовом наборе из публичного набора данных.

Ключевые слова: изображение, диабетическая ретинопатия, обработка изображений, сверточные нейронные сети.

Введение

Задача определения и классификации стадий диабетической ретинопатии, которая проявляется как поражение сетчатки глаза, в настоящее время является весьма актуальной [1, 2]. Диабетическая ретинопатия является основной причиной слепоты, особенно среди людей трудоспособного возраста. Учитывая важность ранней диагностики, все пациенты с сахарным диабетом должны ежегодно проходить офтальмологическое обследование [3, 4].

Глубокое обучение (Deep Learning, DL), как раздел машинного обучения (Machine Learning, ML), за последние десять лет оказало значительное влияние на различные области науки. Это ускорило прогресс в распознавании изображений и речи, предложены эффективные модели генеративных нейронных сетей и новые языковые модели. До широкого распространения глубокого обучения задача анализа и распознавания изображений включала в себя этапы предварительной обработки изображений, вычисления информативных признаков и принятия решений. В настоящее время передовыми технологиями распознавания объектов на изображениях являются использование компьютерного зрения, а также глубокое обучение. Применение глубоких нейронных сетей для идентификации объектов, классификации и сегментации изображений показывает большую эффективность по сравнению с использованием иных классических алгоритмов. Глубокое обучение – это подраздел машинного обучения, включающий в себя набор методов, которые позволяют моделировать высокоуровневые абстракции данных. Модели, построенные на основе сложных нейросетевых архитектур, достигают высокой точности, превышающей возмож-

ности человека. С появлением эффективных архитектур нейронных сетей этап вычисления признаков, как и принятие решений, выполняются на стороне нейронной сети. Предварительная обработка изображений чаще всего сводится к операциям изменения размера изображения и локализации области интереса. Однако с ростом точности распознавания очевиден и рост сложности архитектур, необходима «тонкая» настройка гиперпараметров нейронных сетей. Сверточные нейронные сети (Convolution Neural Networks, CNN) являются ведущей архитектурой при решении задач компьютерного зрения.

Системы глубокого обучения играют важную роль в здравоохранении. Анализ изображений сетчатки глаза человека на основе методов машинного обучения в целом, и глубокого обучения в частности позволяет автоматизировать процесс диагностики и помогает в постановке диагноза в тех случаях, когда доступ к другим вариантам исследований и медицинской помощи ограничен [5-10].

Цель проведенных исследований – разработка модели сверточной нейронной сети для определения ДР на основе изображений сетчатки глаза.

Архитектура сверточной нейронной сети EfficientNet

В 2019 г. компания Google представила архитектуру EfficientNet, которая в настоящее время является одной из самых современных сверточных нейронных сетей [11]. Существует 8 реализаций EfficientNet, считая от B0 до B7 по мере роста сложности сетевой архитектуры. Данные архитектуры превосходят точность стандартных CNN и повышают эффективность нейронной сети до 10 раз, рисунок 1.




Рисунок 1. Число параметров (миллионы) [11]

Также в последние несколько лет появились эффективные решения для анализа изображений сетчатки глаза с использованием данной архитектуры [12-15]. Результаты указанных работ свидетельствуют о целесообразности исследования архитектуры *EfficientNet* с целью создания бинарного классификатора для определения ДР.

Архитектура *EfficientNet* основана на базовой сети *EfficientNet-B0*, которая была получена с помощью автоматического поиска архитектур (*neural architecture search*) на основе оптимизации точности и эффективности. Базовая сеть состоит из нескольких блоков свертки с инвертированными бутылочными горлышками (*inverted bottleneck residual blocks*),

которые содержат линейные бутылочные горлышки (*linear bottleneck*), расширяющие свертки (*expansion convolution*), глубокие свертки (*depthwise convolution*) и проекционные свертки (*projection convolution*).

Чаще всего разработка новых моделей заключается в произвольном увеличении глубины или ширины сверточной нейросети, а также использовании большего разрешения входного изображения для обучения и оценки. В отличие от традиционных подходов, которые произвольно масштабируют параметры сети, такие как ширина, глубина и входящее разрешение, *EfficientNet* равномерно масштабирует каждое измерение с фиксированным набором коэффициентов масштабирования, рисунок 2.




Рисунок 2. Сравнение различных методов масштабирования

Примечание. В отличие от обычных методов масштабирования (b)-(d), которые произвольно масштабируют одно измерение сети, комбинированный метод масштабирования (a) равномерно масштабирует все измерения [11]

Для получения более мощных вариантов архитектуры *EfficientNet-B1-B7*, авторы предложили метод масштабирования с коэффициентом составления. Этот метод определяет оптимальное соотношение между разрешением, шириной и глубиной нейросети при заданном ограничении на количество операций

с плавающей точкой в секунду (*FLOPS*). Таким образом, можно получить более крупные и точные модели без произвольного изменения отдельных размерностей. Блочная архитектура *EfficientNet* представлена на рисунке 3.

Блоки, в свою очередь состоят из модулей, рисунок 4.




Рисунок 3. Блочная архитектура *EfficientNet*




Рисунок 4. Модули архитектуры *EfficientNet*

Технологии предобучения и самообучения

Предобучение – очень распространенная практика в различных областях, таких как компьютерное зрение, *NLP* и генерация речи. Когда речь идет о компьютерном зрении, модель, предварительно обученная на одном наборе данных, улучшает качество другой модели. Предобучение на наборе *ImageNet* [16] с учителем является широко используемым методом инициализации для моделей обнаружения и сегментации объектов. Трансферное обучение (*Transfer learning*) и точная настройка (*Fine-tuning*) – два распространенных метода для реализации этой методологии [17-19].

Самообучение (*semi-supervised learning approach*) пытается улучшить эффективность модели за счет включения прогнозов для модели на неразмеченных данных для получения дополнительной информации, которая может быть использована во время обучения. Пример

реализации данной технологии – это использование *ImageNet* [16] для улучшения модели обнаружения объектов *COCO* [20]. Сначала модель обучается на наборе данных *COCO*. Затем она используется для создания псевдо-меток для *ImageNet* (мы отбрасываем исходные метки *ImageNet*). Затем псевдо-размеченные данные *ImageNet* и размеченные данные *COCO* объединяются для обучения новой модели [21, 22].

Реализация технологии самообучения на основе алгоритма *Noisy Student* показало улучшение качества классификации изображений из *ImageNet* [23]. В этом подходе можно выделить из три этапа:

- модель-учитель обучается на размеченных данных, например, на наборе данных *COCO*;
- затем модель-учитель используется для создания псевдометок для неразмеченных данных, например *ImageNet*;

• модель-ученик обучается оптимизировать потери на человеческой разметке и псевдо-метках одновременно.

Обучение на основе *Noisy Student* приводит к значительным улучшениям во всех размерах моделей *EfficientNet*. Это является основание

для построения модели классификатора ДР на основе предобучения в соответствии с алгоритмом *Noisy Student*. В приведенном ниже рисунке использована одна и та же архитектура для учителя и ученика и не проводится итеративное обучение, рисунок 5.




Рисунок 5. Число параметров (миллионы) [23]

Для реализации классификатора ДР использовалась модель *EfficientNet NoisyStudent B4*, предобученная по технологии самообучения. Выбор

данной модели – это компромисс между точность модели и числом параметров [23, 24]. Архитектура модели *EfficientNet B4* представлена на рисунке 6.




Рисунок 6. Число параметров (миллионы) [23]

Набор изображений

В работе использовался открытый набор данных, взятый с платформы *Kaggle*, представленный в виде коллекции изображений разных размеров с форматом «.jpg» [25]. Изображения в наборе разделены на пять классов, соответствующих стадиям ДР. Снимки принадлежат разным людям из различных социальных групп: женщинам, мужчинам, детям. Строение глаза отличается от снимка к снимку, изображения получены в различных условиях, поэтому построить простой детерминированный алгоритм для эффективного

решения задачи детекции ДР не представляется возможным.

Набор данных содержит 3 662 изображений сетчатки глаза человека. Он был перераспределен и сформировано 2 класса изображений: 0 класс – «норма» (отсутствие ДР), 1 класс – «патология» (наличие ДР), который включает в себя изображения с различными стадиями ДР. При проведении экспериментов для контроля обучения и эффективного тестирования набор был разделен на три части: обучающая выборка (2 196 изображений), валидационная выборка (733 изображения) и тестовая выборка (733 изображения). Примеры изображений представлены на рисунке 7.




Рисунок 7. Примеры изображений сетчатки глаза [25]

Экспериментальные исследования

Исходя из вышесказанного в основу модели классификатора изображений сетчатки глаза человека была положена архитектура сверточной нейронной сети *EfficientNet B4*, предобученная по технологии самообучения на основе алгоритма *Noisy Student*.

Оригинальная архитектура модели предусматривает, что на вход выходного линейного слоя подается вектор из 1 792 признаков, а выход содержит 1000 элементов, что соответствует числу классов предобученной на наборе данных *ImageNet* модели. Архитектура была модифицирована с учетом решаемой задачи, добавлены пользовательские слои, а последний слой содержит 2 признака (таблица 1).

При реализации нейронной сети использовался язык программирования *Python* и библиотека глубокого обучения *PyTorch* [26].

В процессе подготовки данных для обучения, валидации и тестирования выполнялась аугментация данных. Под аугментацией данных понимается увеличение выборки данных для обучения через модификацию этих данных и создание на этой основе – дополнительных. Для достижения хороших результатов глубокие сети должны обучаться на очень большом объеме данных. Следовательно, если исходный обучающий набор содержит ограниченное количество изображений, необходимо выполнить аугментацию, чтобы улучшить результаты модели [27].

Таблица 1

Перечень слоев предложенной архитектуры нейронной сети

Перечень слоев нейронной сети	
Слой EfficientNet B4 Noisy Student	
Добавленные пользовательские слои	
Linear(in_features=1792, out_features=625)	линейный слой in_features – количество входных нейронов out_features – количество выходных нейронов
ReLU()	функция активации
Dropout(p = 0.3)	случайным образом обнуляются некоторые элементы входного тензора с вероятностью p, используя выборки из распределения Бернулли
Linear(in_features = 625, out_features = 256)	линейный слой in_features – количество входных нейронов out_features – количество выходных нейронов
ReLU()	функция активации
Linear(in_features = 256, out_features = 2)	линейный выходной слой нейронной сети in_features – количество входных нейронов out_features – количество выходных нейронов

Для экспериментов с аугментацией данных были определены следующие операции:

1) **изменение размера изображения**, приведения к размеру 224*224, 512*512 или 1024*1024 пикселей;

2) **случайный поворот** изображения на +/-20 градусов;

3) **нормализация RGB изображений** с помощью статистических характеристик: средние значения mean = [0.485, 0.456, 0.406] и стандартное отклонение std = [0.229, 0.224, 0.225]. Данная операция рекомендована к использованию в тех случаях, когда применяется предобученная на ImageNet модель [26]. Значения рассчитаны

для изображений из базы ImageNet. Для каждого канала операция выполняется в соответствии с формулой:

$$\text{image} = \text{image} * \text{std} + \text{mean},$$

где image – канал изображения, std – стандартное отклонение, mean – среднее.

4) **обрезка фона**, который иногда занимает значительный процент от общей площади изображения и является практически черной и неинформативной областью.

Комбинации операций аугментации при проведении экспериментов приведены в таблице 2.

Таблица 2

Аугментация данных при постановке экспериментов

Номер операции аугментации	Эксперимент 1	Эксперимент 2	Эксперимент 3	Эксперимент 4
1	+(512*512)	+(512*512)	+(224*224)	+(1024*1024)
2	+	+	+	+
3	+	+	+	+
4	–	+	+	+

В процессе обучения необходимо минимизировать функцию ошибки, в идеале свести ее к значению в локальном минимуме. Реализация алгоритма градиентного спуска для нейронных сетей происходит с использованием так называемых оптимизаторов. В работе используется оптимизатор *Adam* [28] – один из самых эффективных алгоритмов оптимизации в обучении нейронных сетей. Он сочетает в себе идеи *RMSProp* и стохастического градиентного спуска с моментами. Вместо того чтобы адаптировать скорость обучения параметров на основе среднего первого момента (среднего значения), как в *RMSProp*, *Adam* также использует среднее значение вторых моментов градиентов.

Для оценки результатов использовалась метрика доли правильных ответов (*Accuracy*) – это доля правильно классифицированных объектов от общего числа объектов. В качестве функции потерь (*Loss*) использовалась кросс-энтропия (перекрестная энтропия) [29].

Классификатор обучалась в соответствии со следующими параметрами:

- число эпох обучения (*epochs*) – 10;
- коэффициент скорости обучения (*learning rate*) – 0,001;
- число пакетов данных в одной итерации (*batch size for dataset*) – 16.

В таблице 3 приведены результаты экспериментов, значения нормированы от 0 до 1.

Таблица 3

Результаты экспериментов

	Обучение		Валидация		Тестирование	
	Loss	Accuracy	Loss	Accuracy	Loss	Accuracy
Эксперимент 1	0.1375	0.9565	0.1434	0.9578	0.1040	0.9605
Эксперимент 2	0.1108	0.9574	0.1542	0.9592	0.0882	0.9670
Эксперимент 3	0.1581	0.9447	0.1811	0.9270	0.1689	0.9399
Эксперимент 4	0.1207	0.9592	0.1245	0.9646	0.0918	0.9714

Результаты экспериментов показали, что предложенная архитектура модели в сочетании с определенными техниками аугментации, а также технология самообучения, позволяют достичь доли правильно классифицированных объектов равной 97,14 % на тестовом наборе данных из публичного набора [25]. Зачастую именно определение ДР, играет решающую роль для своевременного лечения и предотвращения тяжелых последствий заболевания.

Дальнейшие исследования целесообразно продолжить в части расширения набора данных для построения вариативных моделей. Кроме того, важным вопросом является детекция визуальных признаков наличия ДР и разработка для этого моделей нейронных сетей на базе сверточных архитектур и трансформеров.

Заключение

В статье предложена архитектура нейросетевого классификатора для решения задачи определения ДР по изображениям сетчатки. В основу модели классификатора изображений сетчатки глаза человека была положена архитектура сверточной нейронной сети *EfficientNet B4*, предобученная по технологии самообучения на основе алгоритма *Noisy Student*. Отдельное внимание уделено этапу аугментации данных, подбору эффективного сочетания операций. Экспериментальные исследования показывают, что возможно достичь доли правильно классифицированных объектов равной 97,14 %. Автором решена практическая задача и определены направления дальнейших исследований.

ЛИТЕРАТУРА

1. Bourne, R.R. Vision Loss Expert Group. Causes of vision loss worldwide, 1990-2010: a systematic analysis / R.R. Bourne, G.A. Stevens, R.A. White, J.L. Smith, S.R. Flaxman, H. Price, J.B. Jonas, J. Keeffe, J. Leasher, K. Naidoo, K. Pesudovs, S. Resnikoff, H.R. Taylor // *Lancet Glob Health* - 2013. – Т. 1, № 6. – С. 339-349. doi: 10.1016/S2214-109X(13)70113-X
2. Taylor, R., Batey, D. Handbook of retinal screening in diabetes. – Wiley, 2006.

3. **The Diabetic Retinopathy Clinical Research Network: Aflibercept, bevacizumab, or ranibizumab for diabetic macular edema.** *N Engl J Med* 372(13):1193-1203, 2015. doi: 10.1056/NEJMoa1414264
4. **Beaulieu, W.T., Bressler, N.M., Melia, M., et al.** Panretinal photocoagulation versus ranibizumab for proliferative diabetic retinopathy: Patient-centered outcomes from a randomized clinical trial. *Am J Ophthalmol* 170:206-213, 2016. doi: 10.1016/j.ajo.2016.08.008
5. **Mookiah, M.R.K., Acharya, U.R., Chua, C.K., Lim, C.M., Ng, E., Laude, A.** Computer-aided diagnosis of diabetic retinopathy: a review. *Comput Biol Med.* 2013;43(12):2136–2155. doi: 10.1016/j.combiomed.2013.10.007
6. **Lam, C., Yi, D., Guo, M., Lindsey, T.** Automated detection of diabetic retinopathy using deep learning. *AMIA Summit Translat Sci Proc.* 2018;2018:147.
7. **Bargshady, G., Zhou, X., Deo, R., Soar, J., Whittaker, F., Wang, H.** Enhanced deep learning algorithm development to detect pain intensity from facial expression images. *Expert Syst Appl.* 2020;149:113305. doi: 10.1016/j.eswa.2020.113305
8. **Sarki, R., Ahmed, K., Wang, H., Zhang, Y.** Automatic detection of diabetic eye disease through deep learning using fundus images: a survey. *IEEE Access.* 2020;8:151133–151149. doi: 10.1109/ACCESS.2020.3015258
9. **Gargeya, R., Leng, T.** Automated identification of diabetic retinopathy using deep learning. *Ophthalmology.* 2017;124(7):962–969. doi: 10.1016/j.ophtha.2017.02.008
10. **Litjens, G., Kooi, T., Bejnordi, B.E., Setio, A.A.A., Ciompi, F., Ghafoorian, M., Van Der Laak, J.A., Van Ginneken, B., Sánchez, C.I.** A survey on deep learning in medical image analysis. *Med Image Anal.* 2017;42:60–88. doi: 10.1016/j.media.2017.07.005
11. **EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks** [Электронный ресурс]. – Режим доступа: <https://arxiv.org/abs/1905.11946>
12. **Wang, Jing & Yang, Liu & Huo, Zhanqiang & He, Weifeng & Luo, Junwei.** (2020). Multi-Label Classification of Fundus Images With EfficientNet. *IEEE Access.* 8. 212499-212508. 10.1109/ACCESS.2020.3040275.
13. **Parthiban, K., Kamarasan, M.** EfficientNet with Optimal Wavelet Neural Network for DR Detection and Grading, 2022 4th International Conference on Smart Systems and Inventive Technology (ICSSIT), Tirunelveli, India, 2022, pp. 1081-1086, doi: 10.1109/ICSSIT53264.2022.9716528
14. **Bulut, B., Kalın, V., Bektaş Güneş, B. & Khazhin, R.** (2022). Classification of Eye Disease from Fundus Images Using EfficientNet. *Artificial Intelligence Theory and Applications*, 2(1), 1-7. Retrieved from <https://dergipark.org.tr/en/pub/aita/issue/70443/1134144>
15. **Zhu, S., Lu B., Wang, C, Wu, M., Zheng, B., Jiang, Q., Wei, R., Cao, Q., Yang, W.** Screening of Common Retinal Diseases Using Six-Category Models Based on EfficientNet. *Front Med (Lausanne).* 2022 Feb 23;9:808402. doi: 10.3389/fmed.2022.808402. PMID: 35280876; PMCID: PMC8904395.
16. **ImageNet** [Электронный ресурс]. – Режим доступа: <https://www.image-net.org/>. – Дата доступа : 28.08.2023.
17. **Deep transfer learning for image classification: a survey** [Электронный ресурс]. – Режим доступа: <https://arxiv.org/abs/2205.09904>. – Дата доступа : 28.08.2023.
18. **Kim, H.E., Cosa-Linan, A., Santhanam, N. et al.** Transfer learning for medical image classification: a literature review. *BMC Med Imaging* 22, 69 (2022). doi: 10.1186/s12880-022-00793-7
19. **Zhou, Z., Shin, J., Zhang, L., Gurudu, S., Gotway, M., Liang, J.** Fine-tuning Convolutional Neural Networks for Biomedical Image Analysis: Actively and Incrementally. *Proc IEEE Comput Soc Conf Comput Vis Pattern Recognit.* 2017 Jul;2017:4761-4772. doi: 10.1109/CVPR.2017.506. Epub 2017 Nov 9. PMID: 30337799; PMCID: PMC6191179.
20. **COCO – Common Objects in Context** [Электронный ресурс]. – Режим доступа: <https://cocodataset.org/>. – Дата доступа : 28.08.2023.
21. **Rethinking ImageNet Pre-training** [Электронный ресурс]. – Режим доступа: <https://arxiv.org/pdf/1811.08883.pdf>. – Дата доступа : 28.08.2023.
22. **Rethinking Pre-training and Self-training** [Электронный ресурс]. – Режим доступа: <https://arxiv.org/pdf/2006.06882.pdf>. – Дата доступа : 28.08.2023.
23. **Self-training with Noisy Student improves ImageNet classification** [Электронный ресурс]. – Режим доступа: <https://arxiv.org/pdf/1911.04252.pdf>. – Дата доступа : 28.08.2023.
24. **Models** [Электронный ресурс]. – Режим доступа: https://github.com/rwightman/pytorch-image-models/releases/download/v0.1-weights/tf_efficientnet_b4_ns-d6313a46.pth. – Дата доступа : 28.08.2023.
25. **APTOS 2019 Blindness Detection** [Электронный ресурс]. – Режим доступа: <https://www.kaggle.com/c/aptos2019-blindness-detection/>. – Дата доступа : 28.08.2023.
26. **PyTorch** [Электронный ресурс]. – Режим доступа: <https://pytorch.org>. – Дата доступа : 28.08.2023.
27. **Image Data Augmentation for Deep Learning: A Survey** [Электронный ресурс]. – Режим доступа: <https://arxiv.org/abs/2204.08610>. – Дата доступа : 28.08.2023.
28. **Adam: A Method for Stochastic Optimization** [Электронный ресурс]. – Режим доступа: <https://arxiv.org/abs/1412.6980>. – Дата доступа : 28.08.2023.
29. **Uses and Abuses of the Cross-Entropy Loss: Case Studies in Modern Deep Learning** [Электронный ресурс]. – Режим доступа: <https://arxiv.org/abs/2011.05231>. – Дата доступа : 28.08.2023.

REFERENCES

1. Bourne, R.R. Vision Loss Expert Group. Causes of vision loss worldwide, 1990-2010: a systematic analysis / R.R. Bourne, G.A. Stevens, R.A. White, J.L. Smith, S.R. Flaxman, H. Price, J.B. Jonas, J. Keeffe, J. Leasher, K. Naidoo, K. Pesudovs, S. Resnikoff, H.R. Taylor // *Lancet Glob Health* – 2013. – T. 1, № 6. – C. 339-349. doi: 10.1016/S2214-109X(13)70113-X
2. Taylor, R., Batey, D. Handbook of retinal screening in diabetes. Wiley (2006).
3. The Diabetic Retinopathy Clinical Research Network: Aflibercept, bevacizumab, or ranibizumab for diabetic macular edema. *N Engl J Med* 372(13):1193-1203, 2015. doi: 10.1056/NEJMoa1414264
4. Beaulieu, W.T., Bressler, N.M., Melia, M., et al. Panretinal photocoagulation versus ranibizumab for proliferative diabetic retinopathy: Patient-centered outcomes from a randomized clinical trial. *Am J Ophthalmol* 170:206-213, 2016. doi: 10.1016/j.ajo.2016.08.008
5. Mookiah, M.R.K., Acharya, U.R., Chua, C.K., Lim, C.M., Ng, E., Laude, A. Computer-aided diagnosis of diabetic retinopathy: a review. *Comput Biol Med.* 2013;43(12):2136–2155. doi: 10.1016/j.combiomed.2013.10.007
6. Lam, C., Yi, D., Guo, M., Lindsey, T. Automated detection of diabetic retinopathy using deep learning. *AMIA Summit Translat Sci Proc.* 2018;2018:147.
7. Bargshady, G., Zhou, X., Deo, R., Soar, J., Whittaker, F., Wang, H. Enhanced deep learning algorithm development to detect pain intensity from facial expression images. *Expert Syst Appl.* 2020;149:113305. doi: 10.1016/j.eswa.2020.113305
8. Sarki, R., Ahmed, K., Wang, H., Zhang, Y. Automatic detection of diabetic eye disease through deep learning using fundus images: a survey. *IEEE Access.* 2020;8:151133–151149. doi: 10.1109/ACCESS.2020.3015258
9. Gargeya, R., Leng, T. Automated identification of diabetic retinopathy using deep learning. *Ophthalmology.* 2017;124(7):962–969. doi: 10.1016/j.ophtha.2017.02.008
10. Litjens, G., Kooi, T., Bejnordi, B.E., Setio, A.A.A., Ciompi, F., Ghafoorian, M., Van Der Laak, J.A., Van Ginneken, B., Sánchez, C.I. A survey on deep learning in medical image analysis. *Med Image Anal.* 2017;42:60–88. doi: 10.1016/j.media.2017.07.005
11. EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks [Electronic resource]. – Available: <https://arxiv.org/abs/1905.11946>
12. Wang, Jing & Yang, Liu & Huo, Zhanqiang & He, Weifeng & Luo, Junwei (2020). Multi-Label Classification of Fundus Images With EfficientNet. *IEEE Access.* 8. 212499-212508. 10.1109/ACCESS.2020.3040275
13. Parthiban, K., Kamarasan, M. EfficientNet with Optimal Wavelet Neural Network for DR Detection and Grading, 2022 4th International Conference on Smart Systems and Inventive Technology (ICSSIT), Tirunelveli, India, 2022, pp. 1081-1086, doi: 10.1109/ICSSIT53264.2022.9716528
14. Bulut, B., Kalın, V., Bektaş Güneş, B. & Khazhin, R. (2022). Classification of Eye Disease from Fundus Images Using EfficientNet. *Artificial Intelligence Theory and Applications*, 2 (1), 1-7. Retrieved from <https://dergipark.org.tr/en/pub/aita/issue/70443/1134144>
15. Zhu, S., Lu B., Wang, C, Wu, M., Zheng, B., Jiang, Q., Wei, R., Cao, Q., Yang, W. Screening of Common Retinal Diseases Using Six-Category Models Based on EfficientNet. *Front Med (Lausanne).* 2022 Feb 23;9:808402. doi: 10.3389/fmed.2022.808402. PMID: 35280876; PMCID: PMC8904395.
16. ImageNet [Electronic resource]. – Available: <https://www.image-net.org/>. – Date of access : 28.08.2023.
17. Deep transfer learning for image classification: a survey [Electronic resource]. – Available: <https://arxiv.org/abs/2205.09904>. – Date of access : 28.08.2023.
18. Kim, H.E., Cosa-Linan, A., Santhanam, N. et al. Transfer learning for medical image classification: a literature review. *BMC Med Imaging* 22, 69 (2022). doi: 10.1186/s12880-022-00793-7
19. Zhou, Z., Shin, J., Zhang, L., Gurudu, S., Gotway, M., Liang, J. Fine-tuning Convolutional Neural Networks for Biomedical Image Analysis: Actively and Incrementally. *Proc IEEE Comput Soc Conf Comput Vis Pattern Recognit.* 2017 Jul;2017:4761-4772. doi: 10.1109/CVPR.2017.506. Epub 2017 Nov 9. PMID: 30337799; PMCID: PMC6191179.
20. COCO – Common Objects in Context [Electronic resource]. – Available: <https://cocodataset.org/>. – Date of access : 28.08.2023.
21. Rethinking ImageNet Pre-training [Electronic resource]. – Available: <https://arxiv.org/pdf/1811.08883.pdf>. – Date of access : 28.08.2023.
22. Rethinking Pre-training and Self-training [Electronic resource]. – Available: <https://arxiv.org/pdf/2006.06882.pdf>. – Date of access : 28.08.2023.
23. Self-training with Noisy Student improves ImageNet classification [Electronic resource]. – Available: <https://arxiv.org/pdf/1911.04252.pdf>. – Date of access : 28.08.2023.
24. Models [Electronic resource]. – Available: https://github.com/rwightman/pytorch-image-models/releases/download/v0.1-weights/tf_efficientnet_b4_ns-d6313a46.pth. – Date of access : 28.08.2023.
25. APTOS 2019 Blindness Detection [Electronic resource]. – Available: <https://www.kaggle.com/c/aptos2019-blindness-detection/>. – Date of access : 28.08.2023.

26. **PyTorch** [Electronic resource]. – Available: <https://pytorch.org>. – Date of access : 28.08.2023.
27. **Image Data Augmentation for Deep Learning: A Survey** [Electronic resource]. – Available: <https://arxiv.org/abs/2204.08610>. – Date of access : 28.08.2023.
28. **Adam: A Method for Stochastic Optimization** [Electronic resource]. – Available: <https://arxiv.org/abs/1412.6980>. – Date of access : 28.08.2023.
29. **Uses and Abuses of the Cross-Entropy Loss: Case Studies in Modern Deep Learning** [Electronic resource]. – Available: <https://arxiv.org/abs/2011.05231>. – Date of access : 28.08.2023.

LUKASHEVICH M.M.

A NEURAL NETWORK CLASSIFIER FOR DETECTING DIABETIC RETINOPATHY FROM RETINAL IMAGES

*Belarusian State University of Informatics and Radioelectronics
Minsk, Republic of Belarus*

With the spread of diabetes mellitus, diabetic retinopathy (DR) is becoming a major public health problem (especially in developing countries). The long-term complications resulting from DR have a significant impact on patients. Early diagnosis and subsequent treatment can reduce the damage to health. Predictive analytics can be based on the analysis of human retinal images using convolutional neural networks. In this paper, the research focuses on the development of an efficient method for DR detection based on the EfficientNet convolutional neural network, self-learning technology and data augmentation operations. As a result of the experiments, a neural network classifier based on convolutional neural networks is developed, recommendations for data augmentation operations are given. Experiments were performed on the public dataset and showed that it is possible to achieve the proportion of correctly classified objects equal to 97.14 % on the test set from the public dataset.

Keywords: image, diabetic retinopathy, image processing, convolutional neural networks.

Работа частично выполнена в рамках проекта БРФФИ Ф21ПАКГ 001.



Лукашевич Марина Михайловна, кандидат технических наук, доцент, докторант учреждения образования «Белорусский государственный университет информатики и радиоэлектроники».

Lukashevich M.M., PhD, Associate Professor, Postdoctoral Fellow at the Belarusian State University of Informatics and Radioelectronics.

E-mail: lukashevich@bsuir.by

VISHNIAKOU U.A. SHAYA B.H.t

METHODICS AND TOOLS OF COUGH SOUND PROCESSING ON BASIC OF NEURAL NET

*Belarusian state University of Informatics and Radioelectronics
Minsk, Republic of Belarus*

The purpose of the article is to analyze the methods and means of processing cough sounds to detect lung diseases, as well as to describe the developed system for classifying and detecting cough sounds based on a deep neural network. Four types of machine learning and the use of convolutional neural network (CNN) are considered. Hypermarkets of CNN are given. Varieties of machine learning based on the CNN are discussed. The analysis of works on the methodology and means of processing cough sounds based on the CNN with the reduction of the means used and the accuracy of recognition is carried out. Details of machine learning using the environmental sound classification 50 (ESC-50) dataset are discussed. To recognize COVID-19 cough, a classifier was analyzed using CNN as a machine learning model. The proposed CNN system is designed to classify and detect cough sounds based on ESC-50. After selecting a set of sound classification data, four stages are described: extraction of features from audio files, labeling, training, testing. The ESC-50 used for the study was downloaded from the Kaggle website. Python libraries and modules related to deep learning and data science were used to implement the project: NumPy, Librosa, Matplotlib, Hickie, Sci-Kit Learn, Keras. The implemented network used a stochastic gradient algorithm. Several volunteers recorded their voices while coughing using their smartphones and it was assured to record their voices in a public environment to introduce noise to the sounds, in addition to some audio files that were downloaded online. The results showed an average accuracy of 85.37 %, precision of 78.8 % and a recall record of 91.9 %.

Keywords: machine learning, neural network, cough sound processing, cough classification system.

Introduction

Machine learning (ML) uses a data set, which is a table containing rows and columns, information about the classified object. The columns represent a characteristic of the object of interest, and each row represents one object. Predictions and pattern recognition using machine learning can be performed using several types [1].

1. Supervised: input of functions into the algorithm in addition to the result, which is called a class or label. Supervised machine learning is the most commonly used type. Along with this form, there are two main processes: the learning process, in which the algorithm receives big data and allows it to study the output data or result, and the testing phase, in which the remaining data is transmitted to the algorithm to obtain predictions and compare the result.

2. Unsupervised: unlike supervised learning, unsupervised learning is seen as an advanced way of machine learning. An unlabeled data set is passed to an algorithm that will perform its calculations and make predictions without any control.

3. Semi-supervised: a combination of both supervised and unsupervised learning, when algorithms can be assigned a labeled dataset, and training will take place. After that, according to their training, the algorithm continues for the remaining unlabeled datasets.

4. Reinforcement: learning from mistakes, machines can receive a set of instructions and templates that must act according to what is given in their path until the algorithm learns the optimal solution.

With neural networks, both supervised and unsupervised machine learning can be used. Training

of a neural network with a labeled dataset can be performed by correcting the error and updating the weights using the back propagation method by moving backwards from the output layer through the hidden layers until the difference between the errors becomes zero. Unsupervised learning does not have a labeled dataset and depends on the categorization and ordering of the data.

Machine learning algorithms depend on some optimal parameters or hyper-parameters to train the model [2]. Hyper-parameters of NN are defined:

1. Learning rate: a variable that determines the speed of the learning process and parameter updates. The lower the learning rate, the slower the learning process.

2. Momentum: the direction of what will happen next is known by the momentum, which also helps to prevent fluctuations.

3. Batch size: each training iteration uses a certain number of samples, called the batch size.

4. Number of epochs: the number of iterations in which all input data is transmitted back and forth over the network during the learning process. The weights change during each epoch. The number of epochs should be increased until the model is well fitted.

5. The number of hidden layers: between the input and output layers determines the complexity of the network. The optimal number of hidden layers or blocks can be detected when the error remains constant.

In this article we consider the methodology and means of cough recognition using machine learning, neural networks, Python language tools.

Convolutional neural network

Convolutional Neural Network (CNN) has shown high performance in classification and detection in many areas, especially related to pattern recognition, such as image classification, video tagging and sound classification, etc. The term convolution was first mentioned by Lekun et al. [3], since then CNN has become more popular and attracted serious attention of researchers and programmers [3, 4]. CNN consists of input and output layers and three main hidden layers: convolutional, pulling, fully connected.

1. Convolutional layer: convolution is a mathematical operation defined as “an integral that expresses the amount of overlap of one function g when it is shifted by another function f ” [3], used in a convolutional layer for unification.

2. Pulling layer: dimension reduction is performed inside this layer, this is also called downsampling. There are two types of this layer: maximum and average union.

3. Fully connected layer: before reaching the output layer, each neuron in the output layer connects to each node in this layer.

Sound processing

Encoding of audio signals can be represented in two main types: analog, and digital. Second is more widely used, in which the sound wave is sampled at a certain speed, includes MP3 and WAV types [5]. Audio objects are extracted according to audio data standards. They include the abstraction level (high, mid, low), the time domain (instantaneous, segment level, global), the signal domain (time domain, frequency, time-frequency). The article [6] discusses two types of sound functions in ML:

1. Traditional ML: The input data for the ML model are functions, including both time and frequency domains. An example of the most widely used functions is the Zero crossing rate (ZCR).

2. Deep learning: The approach is based on CNN and RNN methods for extracting signal features, using feature extraction methods known as spectrograms, Mel- spectrograms, Mel-frequency cepstrum coefficients (MFCC), perception linear prediction (PLP) and linear prediction coding (LPC).

a. PLP: Feroze et al. proposed a CNN classifier for detecting sound events in a polyphonic environment, where the PLP feature extraction method was used for transmission to the network [7]. The authors in [8] presented a comparative cough detection system. They encoded audio signals to visualize them as images and transmit them to CNN using 5 different PLP techniques. The RASTA-PLP spectral method showed best performance among others with an average accuracy of 0.99.

b. LPC: is considered a function of the time domain. Chowdhury et al. [9] proposed an approach to

speaker recognition using MFCC and LPC functions, which are considered to be frequently used functions. These functions are combined with the use of 1D triplet CNN to improve speaker recognition performance.

c. MFCC: since audio signals are considered non-stationary, so that the values change rapidly over time, most feature extraction methods depend on short-term processing. MFCC are based on the perception of human hearing, since the perception of hearing takes into account the magnitude of the frequency components. Compared to perception of frequencies and magnitudes by human hearing, MFCC uses a nonlinear representation of magnitudes, frequency scaling using filter banks.

A deep CNN with two convolutional layers and two connected layers was trained and tested on the basis of MFCC with a low frequency for three different sets of environmental data in the work [10]. The results of the evaluation after cross-validation training using 10-folds and 5- folds validation showed accuracy for each data set of 64.5 %, 73.1 % and 73.7 %.

Cough detection methods

Bales et al. [11] presented a respiratory infection monitoring tool using CNN to detect cough sounds in order to diagnose bronchitis, bronchiolitis and pertussis. The environmental sound classification (ESC) dataset was used to feed to CNN, which was pre-processed, the lines were labeled as coughing and non-coughing with 993 samples for each. The raw audio signals from the dataset were converted into a Mel spectrogram, resulting in 432x288x3 images, which, in turn, were converted to grayscale. The CNN structure proposed to reduce its complexity consisted of 5 layers: a 2x2 max pooling layer, two convolutional layers, a ReLU activation function, and a 2x2 max pooling layer, in addition to the mel spectrogram image as an input and output layer. The results obtained after dividing the data set by 70-15-15 % in the quality of training, testing and verification showed an F1 score of 89.35 %.

The authors in [12] evaluated CNN for detecting cough sounds, where the sound sounds were segmented, and STFT was performed to obtain 64x16 spectrograms for a convolutional neural network, and labeled as coughing and non-coughing. CNN consists of five layers, 2 convolutional, 2 fully connected and a Softmax classification layer. The final data set contained 627 samples of cough sounds, also sampled up to 44.1 kHz and 16 kHz. Five experiments were conducted to evaluate the models. Comparative tables showed that the model was able to detect cough with a high accuracy of 82.5 %.

A diagnostic approach to pneumonia was proposed in [13] using logistic regression as a machine learning classifier. Mel Cepstral coefficients and non-Gaussianity index characteristics were added together with the extracted wavelet characteristics from the collected sounds. With the help of a microphone, a data set was collected from 91 patients suffering even from

pneumonia, asthma or bronchitis. Sensitivity of 94 % and specificity of 63 % were achieved using wavelet functions. However, after combining other features, the specificity increased to 88 %.

Using CNN, the authors in [14] proposed a cough detection model to prove the possibility of obtaining high performance using sounds recorded by mobile phones. 43 volunteers were asked to cough 20 times at two different distances using 5 different smart phones. The sampling rate was 44.1 kHz, and the data transfer rate was 16 bits. The final data set consisted of 6737 samples labeled as cough and 8854 labeled as control sounds. The results of the two implemented scenarios were evaluated and compared with the previous work, which showed an improvement in accuracy that reached 91.7 % using the CNN and Mel-spectrogram in the first scenario. They also recorded an accuracy of 86.7 % in the second scenario using the same algorithm.

Using Tensorflow, a deep learning library from Google, Khomse et al. [15] presented a cough detection method using a deep learning network. Principal component analysis was implemented as a feature extraction method. The data set was collected with the help of eight volunteers to record cough sounds using a microphone connected to a raspberry pi, which has a sampling rate of 44.1 kHz. The final data set contained a total of 810 sounds, 229 of them are productive sounds, 74 are unproductive and finally 507 were sounds unrelated to coughing. The division of the training test was divided by 70/30 % in such a way that two types of experiments were used to create the model: the first is to evaluate the dataset using DLN only, and the second is using PCA with DLN.

Cough detection using the ESC 50 dataset

A machine learning approach using ESC-50 dataset was proposed in [16]. MFCC was first used as an object extraction method to extract 5000x36 objects, then PCA was applied to reduce the dimension to 1D vector 107. Random frog, UVE algorithm and VIP algorithm were used to reduce complexity and select informative features. After applying the feature selection methods,

the SVM linear classifier was applied to classify sounds into coughing and non-coughing sounds. UVE with 20 functions showed the best performance results with an F1 score of 95 %.

ESC 50 in addition to two other datasets FSDKaggle2018 and Coughvid were evaluated in [17] in order to eliminate symptoms associated with breathing. CoughNet, the proposed model, takes input data in the form of a Mel-spectrogram and imports it into CNN. The model is applied to a CNN-LSTM processor that accepts records as input. The prototype is developed using Verilog HDL on the Xilinx Kintex-7 160t FPGA, which has a lower power consumption.

To classify the COVID-19 cough, Bansal et al. [18] implemented a cough classifier using CNN as a machine learning model. Audioset and ESC-50 were the two selected datasets to train their model, which are labeled COVID and non-COVID in addition to MFCC and spectrogram as feature extraction methods for the proposed model. The dataset contained 871 YouTube videos and 40 audio files, which were reduced to 501 audio files separated for training and testing. The CNN architecture consists of three convolutional layers and three fully connected layers. The overall accuracy of the resulting model was 70 %.

The proposed cough detection system based on CNN

The proposed system is designed to classify and detect cough sounds. After selecting a sound classification dataset, there are four main steps. The first step is to extract features from audio files, such as MFCCs, chromagram, Mel-spectrogram, spectral contrast and tonal centroid features. The second stage is the labeling stage, so we classify the sound samples into coughing and non-coughing, then we enter the input data into CNN. Then we proceed to the training stage and record the results until we reach the optimal parameters in accordance with the best indicators (change in the number of epochs, learning rate, etc.). At the final stage, after creating the model, several tests were applied to the recorded sounds from the volunteers (Figure 1).




Figure 1. Stages of the proposed system

The ESC dataset [19] is a set of 2,000 sound files representing 50 types of environmental sounds. ESC-50 was published in 2015 and has been used in many publications and systems. ESC-50 was used for

research and downloaded from Kaggle's website for data scientists, which contains over 50,000 datasets in addition to over 400,000 publicly available notebooks.

Software environment for implementation

More than 60 % of developers use Python because of its simplicity and a wide range of useful libraries, such as Pandas, Sci-Kit learn, Matplotlib, Seaborn and others. Tensorflow [20], an open source ML platform developed by Google for deep machine learning. Google Colab, designed for Python programmers. Colab specializes in data science and ML, users can import datasets from Kaggle. For our project, the following Python libraries and modules were used, which are related to deep machine learning and data science.

1. NumPy is a library used for structuring arrays, manipulating shapes, sorting. Several functions from NumPy were used, such as the “absolute” function, which was used with the Librosa library to extract short-term fourier transform (STFT) features from audio files.

2. Librosa is an indispensable library used for audio, speech and music analysis. Using Librosa, six methods of feature extraction were applied, starting with STFT, then MFCC and Mel-spectrogram, the remaining three methods were spectral contrast, chroma and tonnetz.

3. Matplotlib: for plotting and visualizing arrays, data and statistics. We used it to construct the matrix of the system and related graphs.

4. Hickle is used to save functions extracted from audio files in HDF5 type format.

5. Sci-Kit Learn: used to implement machine learning algorithms, including supervised and unsupervised. SK-learn was used to obtain model results and metrics like accuracy and recall.

6. Keras: to implement a deep learning model. The training, testing and evaluation of our system is based on Keras and its built-in functions.

Feature extraction

Since our dataset is audio data, we used the Librosa library to extract functions, characteristics (STFT, MFCC, Mel-spectrogram, chroma, spectral contrast and tonnetz) and analyze them. 193 features as total were extracted using Librosa from all the above mentioned methods and resulted in a data-frame that contained 1977 rows and 193 columns from all the input data. The train function accepts the following parameters: objects, labels, type, number of classes, epochs, and optimizer.

The neural network adjusts its weights according to the results obtained after each iteration using various algorithms known as optimizers, which implies calculating the difference between the results. The implemented network uses the stochastic gradient descent as an optimizer for its simplicity, which calculates the gradient of the loss function in the network. The initial learning rate for this system was 0.1 and momentum = 0.9. The functions are those that were saved using Hickle, as well as labels. The number of epochs usually needs to be changed to get the best results, we have increased the number of epochs from 300 to 500, 750, 1200, 1500.

To predict, some sounds were tested and classified using the “predict” function in addition to some recorded cough sounds of volunteers. The prediction method was implemented using a loop to iterate through several audio files and output the accuracy of the detected result for the top three classes that received the highest results. Using the Librosa and Matplotlib libraries, the extracted objects were presented as images showing the different forms of each extraction method.

Several volunteers recorded their voices while coughing using their smart phones and it was assured to record their voices in a public environment to introduce noise to the sounds, in addition to some audio files that were downloaded online. The results showed an average accuracy of 85.37 %, precision of 78.8 % and a recall record of 91.9 %.

Conclusion

1. This thesis introduces the state of art of the most relevant cough detection systems and discuss their obtained results. As well, a well-designed cough detection system was build using the public dataset ESC-50, that was fed a convolutional neural network. The layers of the network as well as the training methods were stated in details.

2. After generating the model, another sound set was tested in order to evaluate the model. Thus, several volunteers recorded their voices while coughing using their smart phones and it was assured to record their voices in a public environment to introduce noise to the sounds, in addition to some audio files that were downloaded online. The results showed an average accuracy of 85.37 %, precision of 78.8 % and a recall record of 91.9 %.

REFERENCES

1. Radhakrishnan P. Towards Data Science. 9 Aug 2017. [Electronic resource]. Available : <https://towardsdatascience.com/what-are-hyperparameters-and-how-to-tune-the-hyperparameters-in-a-deep-neural-network-d0604917584a>. Date of access: Aug 2022.
2. LeCun J., Boser B., Denker J., Henderson D., Howard R., Hubbard W., Jackel L. Backpropagation Applied to Handwritten Zip Code. Neural Computation, 1989. – Vol. 1, No. 4. – Pp. 541-551.
3. Dhillon A., Verma G.K. Convolutional neural network: A review of models, methodologies and applications to object detection. Progress in Artificial Intelligence, 2019. – Vol. 9, No. 2. – Pp. 85-112.

4. **Krizhevsky G.K., Sutskever G.K., Hinton G.E.** ImageNet classification with deep convolutional neural networks // Proceedings of the 25th International Conference on Neural, vol. 60, No. 6, 2012. – Pp. 1097-1105.
5. **Chu, S.** Unstructured Audio Classification for Environment Recognition // Proceedings of the Twenty-Third AAAI Conference on Artificial Intelligence, 2008. – Pp. 1845-1846.
6. **Banchhor K.S., Khan A.** Musical Instrument Recognition using Zero Crossing Rate and Short-time Energy. International Journal of Applied Information Systems. vol. 1, No 3, 2012. – Pp. 85-97.
7. **Feroze K., Maud A.R.** Sound Event Detection in Real Life Audio using Perceptual Linear Predictive Feature with Neural Network // Proceeding of 15th International Bhurban Conference on Applied Sciences & Technology, Islamabad, Pakistan, 2018.
8. **Wang H.-H., Liu J.-M., You M., Li G.-Z.** Audio Signals Encoding for Cough Classification Using Convolutional Neural Networks: A Comparative Study // IEEE International Conference on Bioinformatics and Biomedicine, Shanghai, 2015.
9. **Chowdhury A., Ross A.** Fusing MFCC and LPC Features using 1D Triplet CNN for Speaker Recognition in Severely Degraded Audio Signals. IEEE Transactions on Information Forensics and Security, vol. 15, 2019. – Pp. 1616-1629.
10. **Piczak K.J.** Environmental sound classification with convolutional neural networks // IEEE International workshop on machine learning for signal processing, Boston, 2015.
11. **Bales C., Nabeel M., John N.C., Masood U., Qureshi H., Farooq H.** Can Machine Learning Be Used to Recognize and Diagnose Coughs? // The 8th IEEE International Conference on E-Health and Bioengineering, Romania, 2020.
12. **Amoh A., Odame K.** Deep Neural Networks for Identifying Cough Sounds. IEEE Transactions on Biomedical Circuits and Systems, vol. 10, No. 5, 2016. – Pp. 1003-1011.
13. **Kosasih K., Abeyratne U., Swarnkar V., Triasih R.** Wavelet Augmented Cough Analysis for Rapid Childhood Pneumonia Diagnosis. IEEE Transactions on biomedical engineering, vol. 62, No. 4, 2015. – Pp. 1185-1194.
14. **Barata F., Kipfer K., Weber M., Tinschert P., Fleisch E., Kowatsch T.** Towards Device-Agnostic Mobile Cough Detection with Convolutional Neural Networks // IEEE International Conference on Healthcare Informatics, Xi'an, 2019.
15. **Khomsay S., Vanijjirattikhan R., Suwatthikul J.** Cough detection using PCA and Deep Learning // Intern. Conf. on Information and Communication Technology Convergence (ICTC), Jeju, 2019.
16. **Chen X., Hu X. Zhai G.** Cough Detection Using Selected Informative Features from Audio Signals. Cinnell University, August, 2021.
17. **Rashid H.-A., Mazumder A.N., Pan U., Niyogi K., Mohsenin T.** CoughNet: A Flexible Low Power CNN-LSTM Processor for Cough Sound Detection // IEEE 3rd International Conference on Artificial Intelligence Circuits and Systems (AICAS), Washington DC, 2021.
18. **Bansal V., Pahwa G., Kannan N.** Cough Classification for COVID-19 based on audio mfcc features using Convolutional Neural Networks // IEEE International Conference on Computing, Power and Communication Technologies (GUCON), Greater Noida, 2020.
19. **Piczak K.J.** ESC: Dataset for Environmental Sound Classification // Proceedings of the 23rd Annual ACM Conference on Multimedia, Brisbane, 2015.
20. **Abadi M., Barham P., Chen P., Chen Z., Davis A.** TensorFlow: A System for Large-Scale Machine Learning. Proceedings of the 12th USENIX Symposium on Operating Systems Design and Implementation (OSDI '16). November, 2016 Savannah, GA, USA.

ЛИТЕРАТУРА

1. **Radhakrishnan P.** Towards Data Science. 9 Aug 2017. [Electronic resource]. Available : <https://towardsdatascience.com/what-are-hyperparameters-and-how-to-tune-the-hyperparameters-in-a-deep-neural-network-d0604917584a>. – Data of access: Aug 2022.
2. **LeCun J., Boser B., Denker J., Henderson D., Howard R., Hubbard W., Jackel L.** Backpropagation Applied to Handwritten Zip Code. Neural Computation, vol. 1, No. 4, 1989. – Pp. 541-551.
3. **Dhillon A., Verma G.K.** Convolutional neural network: A review of models, methodologies and applications to object detection. Progress in Artificial Intelligence, vol. 9, No. 2, 2019. – Pp. 85-112.
4. **Krizhevsky G.K., Sutskever G.K., Hinton G.E.** ImageNet classification with deep convolutional neural networks // Proceedings of the 25th International Conference on Neural, vol. 60, No. 6, 2012. – Pp. 1097-1105.
5. **Chu, S.** Unstructured Audio Classification for Environment Recognition // Proceedings of the Twenty-Third AAAI Conference on Artificial Intelligence, 2008. – Pp. 1845-1846.
6. **Banchhor K.S., Khan A.** Musical Instrument Recognition using Zero Crossing Rate and Short-time Energy. International Journal of Applied Information Systems. vol. 1, N 3, 2012. – Pp. 85-97.
7. **Feroze K., Maud A.R.** Sound Event Detection in Real Life Audio using Perceptual Linear Predictive Feature with Neural Network // Proceeding of 15th International Bhurban Conference on Applied Sciences & Technology, Islamabad, Pakistan, 2018.

8. Wang H.-H., Liu J.-M., You M., Li G.-Z. Audio Signals Encoding for Cough Classification Using Convolutional Neural Networks: A Comparative Study // IEEE International Conference on Bioinformatics and Biomedicine, Shanghai, 2015.
9. Chowdhury A., Ross A. Fusing MFCC and LPC Features using 1D Triplet CNN for Speaker Recognition in Severely Degraded Audio Signals. IEEE Transactions on Information Forensics and Security, vol. 15, 2019. – Pp. 1616-629.
10. Piczak K.J. Environmental sound classification with convolutional neural networks // IEEE International workshop on machine learning for signal processing, Boston, 2015.
11. Bales C., Nabeel M., John N.C., Masood U., Qureshi H., Farooq H. Can Machine Learning Be Used to Recognize and Diagnose Coughs? // The 8th IEEE International Conference on E-Health and Bioengineering, Romania, 2020.
12. Amoh A., Odame K. Deep Neural Networks for Identifying Cough Sounds. IEEE Transactions on Biomedical Circuits and Systems, vol. 10, No. 5, 2016. – Pp. 1003-1011.
13. Kosasih K., Abeyratne U., Swarnkar V., Triasih R. Wavelet Augmented Cough Analysis for Rapid Childhood Pneumonia Diagnosis. IEEE Transactions on biomedical engineering, vol. 62, No. 4, 2015. – Pp. 1185-1194.
14. Barata F., Kipfer K., Weber M., Tinschert P., Fleisch E., Kowatsch T. Towards Device-Agnostic Mobile Cough Detection with Convolutional Neural Networks // IEEE International Conference on Healthcare Informatics, Xi'an, 2019.
15. Khomsay S., Vanijjirattikhan R., Suwatthikul J. Cough detection using PCA and Deep Learning // Intern. Conf. on Information and Communication Technology Convergence (ICTC), Jeju, 2019.
16. Chen X., Hu X. Zhai G. Cough Detection Using Selected Informative Features from Audio Signals. Cinnell University, August, 2021.
17. Rashid H.-A., Mazumder A.N., Pan U., Niyogi K., Mohsenin T. CoughNet: A Flexible Low Power CNN-LSTM Processor for Cough Sound Detection // IEEE 3rd International Conference on Artificial Intelligence Circuits and Systems (AICAS), Washington DC, 2021.
18. Bansal V., Pahwa G., Kannan N. Cough Classification for COVID-19 based on audio mfcc features using Convolutional Neural Networks // IEEE International Conference on Computing, Power and Communication Technologies (GUCON), Greater Noida, 2020.
19. Piczak K.J. ESC: Dataset for Environmental Sound Classification // Proceedings of the 23rd Annual ACM Conference on Multimedia, Brisbane, 2015.
20. Abadi M., Barham P., Chen P., Chen Z., Davis A. TensorFlow: A System for Large-Scale Machine Learning. Proceedings of the 12th USENIX Symposium on Operating Systems Design and Implementation (OSDI '16). November, 2016 Savannah, GA, USA.

ВИШНЯКОВ В.А., САЙЯ Б.Х.

МЕТОДЫ И СРЕДСТВА ОБРАБОТКИ ЗВУКОВ КАШЛЯ НА БАЗЕ НЕЙРОННОЙ СЕТИ

УО «Белорусский государственный университет информатики и радиоэлектроники»
г. Минск, Республика Беларусь

Целью статьи является анализ методики и средств обработки звуков кашля для выявления легочных заболеваний, а также описание разработанной системы для классификации и обнаружения звуков кашля на базе глубокой нейронной сети. Рассмотрены четыре типа машинного обучения, использование сверточной нейронной сети (СНС). Приведены гипермаркеты СНС. Обсуждены разновидности машинного обучения на базе СНС. Выполнен анализ работ по методике и средствам обработки звуков кашля на базе СНС с приведением используемых средств и точности распознавания. Обсуждены детали машинного обучения с использованием набора данных классификации звуков (*environmental sound classification 50 – ESC-50*). Для распознавания кашля COVID-19 проанализирован классификатор, используя CNN в качестве модели машинного обучения. Предлагаемая система СНН предназначена для классификации и обнаружения звуков кашля на базе ESC-50. После выбора набора данных классификации звуков описаны четыре этапа: извлечение признаков из аудиофайлов, маркировки, обучение, тестирование. ESC-50, использованный для исследования, был загружен с веб-сайта Kaggle. Для реализации проекта были использованы библиотеки и модули Python, которые связаны с глубоким обучением и наукой о данных: NumPy, Librosa, Matplotlib, Hickel, Sci-Kit Learn, Keras. Реализованная сеть использовала алгоритм стохастического градиента. Несколько добровольцев записали свои голоса во время кашля с помощью своих смартфонов, было гарантировано, что они будут записывать свои голоса в общественных местах, чтобы внести шум в звуки, в дополнение к некоторым аудиофайлам, которые были загружены онлайн. Результаты показали среднюю точность 85,37 %, точность 78,8 % и рекорд отзыва 91,9 %.

Ключевые слова: машинное обучение, нейронные сети, обработка звуков кашля, система классификации кашля.



Vishniakou Uladzimir, doctor of technical science, professor of ICT department of Belarusian State University of Informatics and Radioelectronics. Research interest: information management and security, electronic business, intellectual management systems. Mingled of two doctoral counsels of thesis's defense. Author more 400 scientific publications including 6 monographs (1 - English), 4 study books with stamp of education Ministry, 8 volumes manual «Information management», 175 scientific articles.

Вишняков Владимир Анатольевич – д.т.н., профессор профессор БГУИР, каф. ИКТ. Область научных интересов: информационное управление и безопасность, электронный бизнес, интеллектуальные системы управления. Член 2-х докторских Советов по защите диссертаций. Автор более 400 научных работ, в том числе 6 монографий (1 на английском языке), 4-х учебных пособий с грифом Министерства образования, 8-и томного учебного комплекса «Информационный менеджмент», 175 научных статей.

E-mail: vish2002@list.ru

Shaya Bahaa, master of technical science, PhD-student of ICT department of Belarusian State University of Informatics and Radioelectronics.

Сайя Бахаа – магистр технических наук, аспирант кафедры ИКТ БГУИР.

ГИРУЦКИЙ И.И.¹, СЕНЬКОВ А.Г.², РАКЕВИЧ Ю.А.¹

СТАТИСТИЧЕСКИЙ АЛГОРИТМ ОБРАБОТКИ ТЕРМОГРАФИЧЕСКИХ СНИМКОВ ВЫМЕНИ КОРОВЫ ДЛЯ ДИАГНОСТИКИ МАСТИТА С ИСПОЛЬЗОВАНИЕМ КРИТЕРИЯ БАЙЕССА

¹УО «Белорусский государственный аграрный технический университет», г. Минск, Республика Беларусь

²ГП «Центр радиотехники Национальной академии наук Беларуси», г. Минск, Республика Беларусь

Сформулирована математическая задача многогипотезного обнаружения субклинического и клинически выраженного мастита у молочных коров по получаемым в результате цифровой обработки тепловых изображений вымени максимальным значениям температуры вымени. Численным методом последовательного перебора значений определены оптимальные пороговые значения температуры, соответствующие байесовскому критерию минимального среднего риска в указанной выше задаче многогипотезного обнаружения.

Ключевые слова: диагностика мастита, критерий Байеса, цифровая обработка изображений, термография.

Введение

В биотехнической системе производства молока болезни вымени (скрытый или клинический мастит) связаны с большими потерями молока за счет ухудшения качества получаемого молока, уменьшения молочной продуктивности, сокращения срока хозяйственного использования коров [1, 2]. В молочно-товарных хозяйствах Республики Беларусь выбраковывается ежегодно по причине мастита не менее 17 % коров. У 50 % и более лактирующих животных выявляется скрытая форма мастита [1]. Поэтому важным является развитие и автоматизация методов диагностики мастита на ранней, субклинической стадии, что позволит оперативно реагировать на развивающееся заболевание.

Одной из новых технологий в исследовании молочной железы крупного рогатого скота является тепловидение, основанное на регистрации видимого изображения собственного инфракрасного излучения поверхности тела с помощью специальных приборов – термографов [3]. Основа термографии – изменение интенсивности инфракрасного излучения патологического очага: увеличение вследствие усиления кровоснабжения и метаболических процессов или уменьшение в областях с пониженным региональным кровотоком. Достоинством метода тепловидения является возможность быстрого (длительность времени сканирования не более 3,2 сек.) бесконтактного получения изображения зон аномальной температуры молочной железы; при этом он может быть использован на большом количестве животных [3–7]. Температура вымени является случайной величиной вследствие множества факторов: индивидуальных особенностей конкретного животного, температуры окружающей среды, времени суток, степени наполнения вымени молоком и т.д.

Поэтому задача диагностики мастита на основе измеряемого максимального значения температуры вымени является задачей статистического обнаружения. В данной работе предлагается математическая формулировка задачи обнаружения как субклинического, так и клинически выраженного мастита, а также численный метод расчета соответствующих пороговых значений температуры.

Основная часть

Всех коров в стаде с точки зрения диагностики заболевания маститом следует разделить на четыре исходные группы H_i , $i = 1, 2, 3, 4$: здоровые; сомнительные, т.е. группа, промежуточная между здоровыми и субклинической формой мастита; субклиническая форма заболевания маститом и клиническая форма заболевания маститом. При анализе максимальной температуры вымени коровы необходимо принять статистически обоснованное решение об отнесении исследуемой коровы к одной из 4-х групп животных A_k , $k = 1, 2, 3, 4$: отрицательный тест, принимается решение о том, что корова здорова; сомнительный тест, принимается решение о том, что корова относится к сомнительной группе; принято решение о субклинической форме заболевания маститом; принято решение о клинической форме заболевания маститом.

Информационный сигнал на входе обнаружителя – максимальное значение температуры вымени коровы θ , определяемое по результатам обработки теплового изображения вымени, – представляет собой случайную величину. Статистический анализ экспериментальных данных при однократных измерениях [5–7] позволяет сделать вывод о нормальном распределении плотности вероятности максимальной температуры вымени коровы $p(\theta)$ для всех 4-х групп животных:

$$p_i(\theta) = \frac{1}{\sigma_i \sqrt{2\pi}} e^{-\frac{(\theta - m_i)^2}{2\sigma_i^2}}, i = 1, 2, 3, 4, \quad (1)$$

где $i = 1, 2, 3, 4$ – номер группы животных;
 m_i, σ_i – значения математического ожидания и средне-
 квадратичного отклонения (СКО) для i -й группы,
 приведенные ниже в таблице 1.

Таблица 1

Статистические характеристики нормального распределения максимального значения температуры вымени коровы [5–7]

Показатели	H_1 – здоровые коровы (-)	H_2 – сомнительные коровы (+)	H_3 – субклинический мастит (++)	H_4 – клинический мастит (+++)
Объем выборки (число коров)	30	30	30	30
$m_i, ^\circ\text{C}$	36,2	37,3	38,5	39,6
$\sigma_i, ^\circ\text{C}$	0,650	0,217	0,198	0,209

Задача обнаружения сигнала является вероятностной. В соответствие с подходом Байеса [8], поставим в соответствие каждому из возможных событий $H_i A_k$ некоторый риск C_{ik} , характеризующий стоимость последствий, которые наступают вслед за возникновением той или иной ситуации. События $H_1 A_1, H_2 A_2, H_3 A_3$ и $H_4 A_4$ соответствуют случаям, когда принимается правильное решение, поэтому можно изначально положить соответствующие риски равными нулю:

$$C_{11} = C_{22} = C_{33} = C_{44} = 0.$$

Путем выбора значений рисков для остальных 12 возможных ситуаций можно задать, какая из них является более нежелательной. В качестве примера в таблице 2 приведен с соответствующими обоснованиями один из практически возможных наборов численных значений рисков для задачи обнаружения мастита. В общем случае соответствующие числовые значения рисков должны определяться с использованием методов экспертных оценок [9] с привлечением в качестве экспертов специалистов-зоотехников.

Оптимальным по критерию Байеса является правило принятия решения, обеспечивающее минимальное значение среднего риска [8]:

$$\bar{C} = \sum_{i=1}^4 \sum_{j=1}^4 C_{ij} P(H_i A_j) \rightarrow \min. \quad (2)$$

Преобразуем выражение для среднего риска с учетом теоремы о произведении событий [8]:

$$\bar{C} = \sum_{i=1}^4 \sum_{j=1}^4 C_{ij} P(H_i) P(A_j / H_i). \quad (3)$$

Введя в рассмотрение для четырех групп животных, соответственно, три не известные пока пороговые значения температуры $\theta_1, \theta_2, \theta_3$, схематически показанные на рис. 1, условные вероятности из формулы (3) определим далее в следующем виде:

$$\begin{aligned} P(A_1 / H_i) &= \int_{-\infty}^{\theta_1} p_i(\theta) d\theta, \\ P(A_2 / H_i) &= \int_{\theta_1}^{\theta_2} p_i(\theta) d\theta, \\ P(A_3 / H_i) &= \int_{\theta_2}^{\theta_3} p_i(\theta) d\theta, \\ P(A_4 / H_i) &= \int_{\theta_3}^{+\infty} p_i(\theta) d\theta, \end{aligned} \quad (4)$$

где $i = 1, 2, 3, 4$ – номера соответствующих гипотез; p_i – плотность вероятности максимальной температуры вымени при выполнении гипотезы H_i , рассчитываемая по формуле (1).

Значения априорных вероятностей $P(H_1), P(H_2), P(H_3), P(H_4)$ в общем случае также должны определяться с использованием методов экспертных оценок. Так, например, по данным работ [10, 11] разовые диагностические исследования 19864 коров в 30 хозяйствах Республики Беларусь показали, что воспалительные процессы в вымени обнаруживаются в среднем в 12 % случаев (заболеваемость коров маститами колебалась от 6,8 % до 21,3 %). При этом субклинический мастит среди других форм воспаления вымени составляет в среднем 62,5 %, в то время как клинически выраженный

регистрируется от 1,6 % (геморрагический) до 21,1 % (катаральный) [12]. Исходя из этих данных, с учетом ограничения:

$$\sum_{i=1}^4 P(H_i) = 1,$$

(6)

получим следующие значения априорных вероятностей:

$$P(H_3) = 0.12 \cdot 0.625 = 0.075,$$

$$P(H_4) = 0.12 \cdot 0.211 = 0.0253,$$

(7)

$$P(H_1) = P(H_2) = \frac{(1 - P(H_3) - P(H_4))}{2} = \frac{(1 - 0.075 - 0.0253)}{2} \approx 0.45.$$

Таблица 2

Примерные практические значения рисков, соответствующие возможным ситуациям в задаче идентификации мастита

Событие	Риск	Примечание
$H_1 A_2$	$C_{12} = 0$	Здоровая корова отнесена к сомнительным
$H_1 A_3$	$C_{13} = 1$	Здоровая корова отнесена к субклиническим: ущерб – лишние затраты труда на лабораторную диагностику
$H_1 A_4$	$C_{14} = 0$	Здоровая корова отнесена к субклиническим: ущерб – лишние затраты труда на лабораторную диагностику
$H_2 A_1$	$C_{21} = 2$	Сомнительная корова отнесена к здоровым: ущерб – возможный пропуск начальной стадии мастита, возможное ухудшение качества получаемого молока
$H_2 A_3$	$C_{23} = 3$	Сомнительная корова отнесена к субклиническим: ущерб – лишние затраты труда на лабораторную диагностику
$H_2 A_4$	$C_{24} = 3$	Сомнительная корова отнесена к клиническим: ущерб – лишние затраты труда на лабораторную диагностику
$H_3 A_1$	$C_{31} = 10$	Субклиническая корова отнесена к здоровым: ущерб – пропуск больной коровы, снижение надоя, ухудшение качества получаемого молока
$H_3 A_2$	$C_{32} = 10$	Субклиническая корова отнесена к сомнительным: ущерб – пропуск больной коровы, снижение надоя, ухудшение качества получаемого молока
$H_3 A_4$	$C_{34} = 0$	Субклиническая корова отнесена к клиническим: пропуска больной коровы нет, лишних затрат труда на диагностику нет, т.к. лабораторная диагностика нужна в любом случае
$H_4 A_1$	$C_{41} = 15$	Клиническая корова отнесена к здоровым: ущерб – пропуск больной коровы, снижение надоя, ухудшение качества получаемого молока
$H_4 A_2$	$C_{42} = 15$	Клиническая корова отнесена к сомнительным: ущерб – пропуск больной коровы, снижение надоя, ухудшение качества получаемого молока
$H_4 A_3$	$C_{43} = 0$	Клиническая корова отнесена к субклиническим: пропуска больной коровы нет, лишних затрат труда на диагностику нет, т.к. лабораторная диагностика нужна в любом случае




Рисунок 1. Распределение плотности вероятности максимальной температуры вымени коровы для 4-х групп животных по степени заболевания маститом

Таким образом, подставляя выражения (4), (6) в формулу (3), с учетом оптимизационного критерия (2) получим оптимизационную задачу для поиска пороговых значений θ_1 , θ_2 , θ_3 квазиоптимальной системы обнаружения мастита. Решив данную задачу численно в среде *Matlab*, получим следующие пороговые значения:

$$\theta_1 = 36,8 \text{ }^{\circ}\text{C}; \theta_2 = 38,0 \text{ }^{\circ}\text{C}; \theta_3 = 39,0 \text{ }^{\circ}\text{C};$$

Заключение

В работе сформулирована математическая задача многогипотезного обнаружения субкли-

нического и клинически выраженного мастита у молочных коров по получаемым в результате цифровой обработки тепловых изображений вымени максимальным значениям температуры вымени. Предложен пример экспертного задания значений рисков. Численным методом последовательного перебора значений определены оптимальные пороговые значения температуры, соответствующие байесовскому критерию минимального среднего риска в указанной задаче многогипотезного обнаружения.

ЛИТЕРАТУРА

1. Лучко, И.Т. Воспаление молочной железы у коров (этиология, патогенез, диагностика, лечение и профилактика) : монография / И.Т. Лучко. – Гродно: ГГАУ, 2019. – 184 с. – ISBN 978-985-537-141-1.
2. **Организационно-технологические требования при производстве молока на молочных комплексах промышленного типа** (Одобрены Постановлением коллегии Министерства сельского хозяйства и продовольствия Республики Беларусь от 4 июня 2018 г. № 16) [Электронный ресурс]. – Режим доступа: https://mshp.gov.by/documents/animal/trebovaniya_moloko.pdf, свободный. – Яз. рус.
3. Колчина, А.Ф. Перспективы применения инфракрасной термографии в исследовании молочной железы коров / А.Ф. Колчина, А.К. Липчинская // Аграрный вестник Урала. – 2010. – № 9(75)6. – С. 94-97.
4. Rodríguez C., Matamoros A., Valilla J. Application of the thermography study of big ruminants udder and its possible pathological complications // RCCV. – Vol. 2 (2). – 2008. – P. 66-72.
5. Гируцкий, И.И. Анализ инфракрасного изображения вымени коров / И.И. Гируцкий, В.И. Передня, Ю.А. Ракевич // Агропанорама. – 2018. – № 6. – С. 9-12.
6. Ракевич, Ю.А. Использование инфракрасной термографии для выявления мастита коров / Ю.А. Ракевич // Агропанорама. – 2020. – № 5. – С. 19-22.
7. Hirutski, I.I. Selection of the information parameter for the thermography method of diagnostics of dairy cows mastitis / I.I. Hirutski, Y.A. Rakevich, A.G. Senkov // International scientific journal «Mechanization in agriculture & conserving of the resources: Bulgaria, 2021 – P. 14-18.
8. Ван Трис Г. Теория обнаружения, оценок и модуляции. Том III. Обработка сигналов в радио- и гидролокации и прием случайных гауссовых сигналов на фоне помех. Нью-Йорк, 1971. Пер. с англ. Под ред. проф. В.Т. Горяинова. М., «Сов. радио», 1977, 664 с.
9. Орлов А.И. Экспертные оценки. Учебное пособие. – М.: 2002. – 31 с.
10. Богуш, А.А. Заболеваемость коров маститами на животноводческих фермах / А.А. Богуш, В.И. Иванов, В.Г. Голынец // Ветеринарная медицина Беларуси. – 2001. – № 1. – С. 41-42.
11. Богуш, А.А. Мастит / А.А. Богуш, В.И. Иванов // Ветеринарная газета. – 2000. – № 19. – С. 3.
12. Новиков, О.Г. Рациональные методы применения диофура для лечения больных маститом коров: автореф. дис. ...канд. вет. наук: 16.00.07 / О.Г. Новиков; Всерос. н.-и. вет. ин-т патологии, фармакологии и терапии. – Воронеж, 1996. – 20 с.

REFERENCES

1. Luchko, I.T. Inflammation of the mammary gland in cows (etiology, pathogenesis, diagnosis, treatment and prevention): monograph / I.T. Luchko. – Grodno: Grodno State Agrarian University, 2019. – 184 p. – ISBN 978-985-537-141-1.
2. **Organizational and technological requirements for the production of milk at industrial-type dairy complexes** (Approved by the Resolution of the Board of the Ministry of Agriculture and Food of the Republic of Belarus of June 4, 2018, No. 16) [Electronic resource]. Access mode: https://mshp.gov.by/documents/animal/trebovaniya_moloko.pdf, free. – lang. rus.
3. Kolchin, A.F. Prospects for the use of infrared thermography in the study of the mammary gland of cows / A.F. Kolchina, A.K. Lipchinskaya // Agrarian Bulletin of the Urals. – 2010. – № 9(75)6. – Pp. 94-97.
4. Rodríguez C., Matamoros A., Valilla J. Application of the thermography study of big ruminants udder and its possible pathological complications // RCCV. – Vol. 2(2). – 2008. – Pp. 66-72.
5. Girutsky, I.I. Analysis of the infrared image of the udder of cows / I.I. Girutsky, V.I. Perednya, Yu.A. Rakevich // Agropanorama. – 2018. – № 6. – Pp. 9-12.
6. Rakevich, Yu.A. Using infrared thermography to detect mastitis in cows / Yu.A. Rakevich // Agropanorama. – 2020. – № 5. – Pp. 19-22.

7. **Hirutski, I.I.** Selection of the information parameter for the thermography method of diagnostics of dairy cows mastitis / I.I. Hirutski, Y.A. Rakevich, A.G. Senkov // International scientific journal «Mechanization in agriculture & conserving of the resources: Bulgaria, 2021 – Pp. 14-18.
8. **Van Tries G.** Theory of detection, estimates and modulation. Vol. III. Processing of signals in radio and sonar and reception of random Gaussian signals against the background of noise. New York, 1971. Translate from English. Ed. prof. V.T. Goryainov. M., “Soviet radio”, 1977, 664 p.
9. **Orlov A.I.** Expert assessments. Tutorial. – M.: 2002. – 31 p.
10. **Bogush, A.A.** Morbidity of cows with mastitis on livestock farms / A.A. Bogush, V.I. Ivanov, V.G. Golynets // Veterinary Medicine of Belarus. – 2001. – № 1. – Pp. 41-42.
11. **Bogush, A.A.** Mastitis / A.A. Bogush, V.I. Ivanov // Veterinary newspaper. – 2000. – № 19. – P. 3.
12. **Novikov, O.G.** Rational methods of using Diofur for the treatment of cows with mastitis: Abstract of the thesis. dis. ...cand. vet. Sciences: 16.00.07 / O.G. Novikov; All-Russian Research Institute of Pathology, Pharmacology and Therapy. – Voronezh, 1996. – 20 p.

HIRUTSKY I.I.¹, SENKOV A.G.², RAKEVITCH Y.A.¹

STATISTICAL BAYESIAN ALGORITHM FOR PROCESSING THERMOGRAPHIC IMAGES OF THE COW UDDER FOR DIAGNOSING MASTITIS

¹*Belarusian State Agrarian Technical University*

²*Radio Engineering Center of the National Academy of Sciences of Belarus
Minsk, Republic of Belarus*

The article presents results of our experiments carried out to study the invariance of the digital description of the image. There in the paper is formulated a mathematical problem of multi-hypothetical detection of subclinical and clinical mastitis in dairy cows by the maximum values of udder temperature measured by digital processing of the udder thermal images. The optimal temperature threshold values corresponding to the Bayesian criterion of the minimum average risk in the above multi-hypothesis detection problem are determined by numerical modelling.

Keywords: *diagnosis of mastitis, Bayes criterion, digital image processing, thermography.*



Гирюцкий Иван Иванович, доктор технических наук, профессор кафедры АСУП БГАТУ, область научных интересов – автоматизация технологических процессов биотехнических объектов АПК.

E-mail: gir_50@mail.ru



Сеньков Андрей Григорьевич, кандидат технических наук, доцент, начальник отдела математического моделирования ГП «Центр радиотехники НАН Беларуси».

Senkov Andrey, G., Ph.d., associate professor, head of the department of mathematical modeling, The Republican Science-and-Production Unitary Enterprise “Radio Engineering Center of the National Academy of Sciences of Belarus”.



Ракевич Юрий Александрович, магистр технических наук, научный сотрудник РУП «НПЦ НАН Беларуси по механизации сельского хозяйства» в лаборатории «Научного обеспечения испытаний и информационно - технических технологий».

Rakevich Yuriy Aleksandrovich, Master of Technical Sciences, researcher of the Republican Unitary Enterprise “SPC of the National Academy of Sciences of Belarus for the mechanization of agriculture” in the laboratory “Scientific support of testing and information and technical technologies”.

E-mail: rakevich.1991@mail.ru

ИТЕРАЦИОННАЯ РЕКОНСТРУКЦИЯ МЕДИЦИНСКИХ ФАНТОМОВ НА ВЫЧИСЛИТЕЛЬНОМ КЛАСТЕРЕ EAGLE

¹ГНУ «Институт прикладной физики НАН Беларуси»

²Белорусский национальный технический университет

³ГНУ «Физико-Технический Институт НАН Беларуси»

г. Минск, Республика Беларусь

В настоящее время одной из наиболее важных задач является разработка и адаптация итерационных методов для решения сверхбольших разреженных систем алгебраических уравнений. К таким вычислительным задачам приводит задача итерационной параллельной реконструкции трехмерных изображений промышленных объектов. Важным является то, что итерационные методы решения вычислительных задач большой размерности реализуются на параллельных структурах намного более эффективно, чем прямые методы их решения.

Ключевые слова: итерационные методы, реконструкция изображений, томография, суперкомпьютер, система MPI.

Введение

Развитие современной вычислительной техники обеспечило появление на рынке большого числа различных суперкомпьютеров с большой вычислительной мощностью. Они успешно применяются для решения разнообразных вычислительных задач в науке и промышленности. Обширный обзор различных параллельных алгоритмов можно найти в известных работах В.Н. Фаддеевой и Д.К. Фаддеева [1-3], В.В. Воеводина [4-6.] На сегодняшний день наиболее распространенными являются системы параллельного программирования на основе интерфейса MPI (Message Passing Interface). Идея MPI [7] проста и очевидна. Она предполагает представление параллельной программы в виде множества параллельно исполняющихся процессов. Одной из наиболее важных задач является разработка и адаптация итерационных методов для решения сверхбольших разреженных систем алгебраических уравнений, к которым и приводит трехмерная томографическая задача. Важным при этом является то, что итерационные методы решения вычислительных задач большой размерности реализуются на параллельных структурах намного более эффективно, чем прямые методы их решения. Большинство алгоритмов, основанных на прямых методах решения, обладают существенной наследственной последовательной структурой и требуют значительного числа взаимодействий между процессорами, которые не могут быть выполнены в параллельном режиме.

Итерационные же методы в большинстве своем требуют значительно меньшего числа взаимодействий подобного типа и сравнительно легко отображаются на параллельные вычислительные структуры. Не менее важно и

то, что в большинстве случаев параллельные реализации классических итерационных методов являются более эффективными в отношении скорости сходимости. Параллельное выполнение алгоритма заключается в том, что вычислительный процесс распределяется между несколькими процессорами. Реализация такого рода параллельных алгоритмов может быть эффективно осуществлена с использованием стандарта MPI. Известны следующие основные формы параллелизма в алгоритмах компьютерной томографии: воксельный, проекционный и лучевой.

Структура и вычислительные ресурсы кластера EAGLE

Институт прикладной физики НАН Беларуси принял участие в европейском проекте *EaPConnect*. *EaPConnect* является финансируемым ЕС проектом. В рамках проекта предусмотрена установка и управление широкополосной интернет-сетью высокой производительности, предоставление услуг, и предлагается возможность для исследования и в рамках образовательных сообществ через Восточное партнерство (*EaP*). *EaPConnect* – часть инициативы Европейского союза *EU4Digital*. В рамках этого проекта наш институт получил доступ к ресурсам вычислительного кластера *EAGLE*, расположенного в городе Познань (Польша). Характеристики вычислительного кластера:

доступ по интернету: eagle.man.poznan.pl. Он имеет 1032 узла (процессоры Intel Xeon E5-2697 2 с 14 ядрами) всего 28 896 ядер; 64, 128 или 256 ГБ ОЗУ на узел. Вычислительная мощность 1,4 PFLOPS. Межблочное соединение Infiniband FRD Ethernet-соединение 1 Гбит/с; система очередей: Slurm. Виды очередей: стандартная, быстрая и другие. Внешний вид кластера показан на рисунке 1.



Рисунок 1. Внешний вид вычислительного кластера EAGLE

В рамках проекта *EaPConnect* наш институт выполнял задание: “*development of a parallel algorithm ILST for the iterative reconstruction of 3D image based on the MPI system*”. Для проверки эффективности разработанных алгоритмов были использованы рентгеновские данные, полученные ранее от Федерального института по исследованию и испытанию материалов (*Bundesanstalt für Materialforschung und -prüfung*) Берлин. Нами были получены два набора рентгеновских проекций:

1) для головы человека (фантом «*Rozi*» и 2) для специального шарообразного фантома «*Kugel*». Всего было получено по 360 проекций для каждого фантома, снятых через угловой интервал один градус. Ниже на рисунке 2 показаны 3 проекции фантома «*Rozi*» для углов 0 градусов, 90 градусов и 180 градусов.

На рисунке 3 показаны 3 проекции фантома «*Kugel*» для углов 0 градусов, 90 градусов и 180 градусов.




Рисунок 2. Проекция фантома «*Rozi*» для углов 0 градусов, 90 градусов и 180 градусов




Рисунок 3. Проекция фантома «*Kugel*» для углов 0 градусов, 90 градусов и 180 градусов

Итерационная реконструкция изображений медицинских фантомов методом *ILST*

Реконструкция фантома «*Rozi*» была осуществлена по 16-битным рентгеновским проекциям с разрешением 1024x1024 пикселя. Размер пикселя был равен 0.4 мм. Размер реконструированного трехмерного изображения составил 1024x1024x1024 кубических вокселей с ребром 0.4 мм. Всего было сделано 10 итераций. Ниже на рисунке 4. показан перспективный вид фантома «*Rozi*».

Для того, чтобы получить представление о внутренней структуре этого фантома на рисунке 5 показаны центральные сечения фантома «*Rozi*» координатными плоскостями XOY, YOZ и XOZ.




Рисунок 4. Перспективный вид фантома «*Rozi*»




Рисунок 5. Центральные сечения фантома «*Rozi*» координатными плоскостями XOY, YOZ и XOZ

Реконструкция фантома «*Kugel*» была осуществлена по 16-битным рентгеновским проекциям с разрешением 512x512 пикселей. Размер пикселя был равен 0.8 мм. Размер реконструированного трехмерного изображения составил 290x290x290 кубических вокселей с ребром 0.8 мм. Всего было сделано 30 итераций. Ниже на рисунке 6. показан перспективный вид фантома «*Kugel*».

На рисунке 7 показаны центральные сечения фантома «*Kugel*» координатными плоскостями XOY, YOZ и XOZ, которые дают полное представление о внутренней структуре этого фантома.

На рисунках видна также подставка, на которой был установлен фантом «*Kugel*» для проведения рентгеновской съемки.



Рисунок 6. Перспективный вид фантома «*Kugel*»




Рисунок 7. Центральные сечения фантома «*Kugel*» координатными плоскостями XOY, YOZ и XOZ

Заключение

Проведенные реконструкции трехмерных изображений медицинских фантомов «Rozi» и «Kugel» показали хорошее качество реконструкций, быструю сходимость итераций как для более малого размера вокселя 0.4 мм, так и для более крупного размера вокселя 0.8 мм. Быстродействие

параллельной реконструкции на порядок больше, чем у последовательных алгоритмов. Показано, что разработанное программное обеспечение может успешно применяться и для медицинских целей, так как позволяет успешно выявить анатомическую структуру важных органов пациентов и сделать необходимые медицинские заключения.

ЛИТЕРАТУРА

1. **Фаддеева, В.Н.** Параллельные вычисления в линейной алгебре / В.Н. Фаддеева, Д.К. Фаддеев // Кибернетика. – 1977. – № 6. – С. 28-40.
2. **Фаддеева, В.Н.** Параллельные вычисления в линейной алгебре / В.Н. Фаддеева, Д.К. Фаддеев // Кибернетика. – 1982. – № 3. – С. 18-31.
3. **Фаддеев, А.К.** Вычислительные методы линейной алгебры / А.К. Фаддеев, В.Н. Фаддеева. – Санкт-Петербург: Лань, 2002. – 736 с.
4. **Воеводин, В.В.** Математические модели и методы в параллельных процессах / В.В. Воеводин. – Москва: Наука, 1986. – 296 с.
5. **Воеводин, В.В.** Параллельные структуры алгоритмов и программ / В.В. Воеводин, Вл. Воеводин. – Москва: ОВМ АН СССР, 1987. – 148 с.
6. **Воеводин, В.В.** Параллельные вычисления / В.В. Воеводин. – Санкт-Петербург: БХВ-Петербург, 2004. – 608 с.
7. **Корнеев, В.Д.** Параллельное программирование в MPI / В.Д. Корнеев. – Москва-Ижевск: Институт компьютерных исследований, 2003. – 304 с.

REFERENCES

1. **Faddeeva V.N.** Parallel calculations in linear algebra / V.N. Faddeeva, D.K. Faddeev // Cybernetics. – 1977. – No. 6. – Pp. 28-40.
2. **Faddeeva V.N.** Parallel calculations in linear algebra / V.N. Faddeeva, D.K. Faddeev // Cybernetics. – 1982. – No. 3. – Pp. 18-31.
3. **Fadeyev A.K.** Computing methods of linear algebra / A.K. Fadeyev, V.N. Fadeyeva. – St. Petersburg: A fallow deer, 2002, 736 p.
4. **Voyevodin V.V.** Mathematical models and methods in parallel processes / V.V. Voyevodin. – Moscow: Science, 1986, 296 p.
5. **Voyevodin V.V.** Parallel structures of algorithms and programs / V.V. Voyevodin. – Moscow: OVM Academy of Sciences of the USSR, 1987, 148 p.
6. **Voyevodin V.V.** Parallel calculations / V.V. Voyevodin, Vl.V. Voyevodin. – St. Petersburg: BHV-St. Petersburg, 2004, 608 p.
7. **Korneev V.D.** Parallel programming in MPI / V.D. Korneev. – Moscow-Izhevsk: Institute of computer researches, 2003, 304 p.

ZOLOTAREV C.A.¹, TARUAT A.T.², BILENKO E.G.³

ITERATIVE RECONSTRUCTION OF MEDICAL PHANTOMS ON THE COMPUTING CLUSTER OF EAGLE

¹*Institute of Applied Physics of the National Academy of Science of Belarus*

²*Belarusian National Technical University*

³*State Scientific Institution "Physico-Technical Institute of the National Academy of Sciences of Belarus"
Minsk, Republic of Belarus*

Now one of the most important tasks is development and adaptation of iterative methods for the solution of the superbig rarefied systems of the algebraic equations. The problem of iterative parallel reconstruction of three-dimensional images of industrial facilities leads to such computing tasks. The fact that iterative methods of the solution of computing problems of big dimension are implemented on parallel structures much more effectively, than direct methods of their decision is important.

Keywords:



Золотарев Сергей Алексеевич

Образование и квалификация:

1978 – инженер по автоматизации химико-технологических процессов, Воронежский технологический институт. 1992 – кандидат физико-математических наук диссертация (Ph.D. эквивалент) дифференциальные уравнения и математическая физика, Институт прикладной физики Национальной академии наук Беларуси. Название диссертации: «Исследование сложных центров и фокусов 2D автономных голоморфных дифференциальных систем». 2010 – доктор технических наук в области приборов и методов контроля природной среды, веществ, материалов и изделий, Институт прикладной физики Национальной академии наук Беларуси.

Название диссертации: «Реконструктивные оболочечные методы и новые вычислительные алгоритмы промышленной томографии».

Область исследований: Специалист в области: решение обратных задач из неполных данных и качественной теории обыкновенных дифференциальных уравнений. Разработчик алгоритмов и программного обеспечения для КТ объектов с ограниченным углом обзора и небольшим числом проекций. Разработчик оболочечных методов реконструкции изображений кусочно-однородных объектов, имеющих конечное число различных однородных частей. Разработчик новых параллельных алгоритмов с использованием графических процессоров и использованием системы MPI для реконструкции изображений.

Краткая научная биография: 1973 по 1978 год - студент Воронежского технологического института. Факультет автоматизации и комплексной механизации производственных процессов. 1978 по 1985 год - работал инженером на различных фирмах России и Беларуси. 1985 по 1988 г. - Научная деятельность в качестве аспиранта в Институте математики Национальной академии наук Беларуси. 1988 по 2011 год - работал научным сотрудником в Институте прикладной физики Национальной академии наук Беларуси.

С 2011 по настоящее время - главный научный сотрудник в Институте прикладной физики Национальной академии наук Беларуси

Главные научные результаты:

Разработал новые методы реконструкции изображений внутренней структуры свойств объектов и соответствующие параллельные алгоритмы реконструкции, которые могут быть использованы при ограниченном доступе к объекту контроля недостаточной мощности рентгеновского источника излучения.

Zolotarev Sergei Alekseevich

Education and qualifications:

1978 – engineer for the automation of chemical and technological processes, Voronezh Technological Institute. 1992 – Candidate of Physical and Mathematical Sciences thesis (Ph . D . equivalent) differential equations and mathematical physics, Institute of Applied Physics of the National Academy of Sciences of Belarus. Thesis title: “Investigation of complex centers and foci of 2 D autonomous holomorphic differential systems”. 2010 – Doctor of Technical Sciences in the field of instruments and methods for monitoring the natural environment, substances, materials and products, Institute of Applied Physics of the National Academy of Sciences of Belarus.

Thesis title: “Reconstructive shell methods and new computational algorithms for industrial tomography”.

Area of research: Specialist in the field: solving inverse problems from incomplete data and the qualitative theory of ordinary differential equations. Developer of algorithms and software for CT objects with a limited viewing angle and a small number of projections. Developer of shell methods for reconstructing images of piecewise homogeneous objects with a finite number of different homogeneous parts. Developer of new parallel algorithms using GPUs and using the MPI system for image reconstruction.

Brief scientific biography: 1973 to 1978 - student at the Voronezh Technological Institute. Faculty of automation and complex mechanization of production processes. 1978 to 1985 - worked as an engineer at various companies in Russia and Belarus. 1985 to 1988 - Scientific activity as a post-graduate student at the Institute of Mathematics of the National Academy of Sciences of Belarus. 1988 to 2011 - worked as a researcher at the Institute of Applied Physics of the National Academy of Sciences of Belarus.

From 2011 to the present - Chief Researcher at the Institute of Applied Physics of the National Academy of Sciences of Belarus

Main scientific results :

Developed new methods for reconstructing images of the internal structure of the properties of objects and the corresponding parallel reconstruction algorithms that can be used with limited access to the object of control of insufficient power of the X-ray source.

E-mail: sergei.zolotarev@gmail.com



Таруат Ахмед Талат Тауфик, в 2018 закончил полный курс Университета Аль-Китаба по специальности “Компьютерные системы коммуникаций”.

Краткая научная биография:

2014-2018 студент Университета Аль-Китаба по специальности “Компьютерные системы коммуникаций”.

2019-2021: Магистратура УО “Белорусский государственный университет информатики и радиоэлектроники” по специальности: информационные коммуникационные системы и сети. Магистр наук в области инженерного дела. В настоящее время аспирант Белорусского национального технического университета, по специальности 05.13.01 “ Системный анализ, управление и обработка информации “

Автор одной научной публикации в журнале «Modern Science: actual problems of theory and practice».

Исследовательские интересы: компьютерная томография, системный анализ, обработка информации.

Taruat Ahmed Talat Taufik

Education: Higher, in 2018 he completed the full course of Al- Kitab University with a degree in Computer Communication Systems.

Brief scientific biography:

2014-2018 student of Al- Kitab University with a degree in Computer Communication Systems.

2019-2021: Master's program of the Belarusian State University of Informatics and Radioelectronics, specialty: information communication systems and networks. Master of Science in Engineering. Currently, Postgraduate student of the Belarusian National Technical University, specialty 05.13.01 “System Analysis, Management and Information Processing”. Author one scientific publications in the journal “Modern Science: actual problems of theory and practice”.

Research interests: computed tomography, system analysis, information processing.

E-mail: mido@bntu.by



Биленко Эдуард Григорьевич, бакалавр технических наук.

Краткая научная биография:

В 1999 году окончил полный курс Белорусской государственной политехнической академии (БГПА) по специальности «Технология, оборудование и автоматизация производства». В 2000 году поступил в аспирантуру при ФТИ НАН Беларуси. В 2004 году окончил аспирантуру по специальности «Материаловедение в машиностроении». В настоящее время работает в ГНУ «ФТИ НАН Беларуси», на должности заместителя заведующего лабораторией.

Основные научные результаты:

Автор пяти статей в научно-технических журналах, десяти научных публикаций с докладами в материалах международных конференций, четырех патентов. Область научных интересов: упрочнение поверхностных слоев материалов, разработка новых композиционных материалов, компьютерное моделирование процессов.

Bilenko Eduard Grigorievich, bachelor of technical sciences.

Brief scientific biography:

In 1999 he graduated from the full course of the Belarusian State Polytechnic Academy (BSPA) with a degree in Technology, Equipment and Automation of Production. In 2000, he entered graduate school at the Institute of Physics and Technology of the National Academy of Sciences of Belarus. In 2004, he completed his postgraduate studies with a degree in Materials Science in Mechanical Engineering. Currently he works at the State Scientific Institution “Physical Institute of Physics and Technology of the National Academy of Sciences of Belarus”, as a deputy head of the laboratory.

Main scientific results:

Author of five articles in scientific and technical journals, ten scientific publications with reports in international conference proceedings, four patents. Research interests: hardening of surface layers of materials, development of new composite materials, computer modeling of processes.

ЗАЩИТА ИНФОРМАЦИИ

INFORMATION SECURITY

ИВАНЮК А.А., ШАМЫНА А.Ю.

ФИЗИЧЕСКИ НЕКЛОНИРУЕМАЯ ФУНКЦИЯ ТИПА АБИТР С НЕЛИНЕЙНЫМИ ПАРАМИ ПУТЕЙ

Белорусский государственный университет информатики и радиоэлектроники,
Минск, Республика Беларусь

Физически неклонируемые функции (ФНФ) являются базовыми элементами физической криптографии, позволяющие решать такие задачи как, неклонируемая идентификация, аутентификация и доказательство авторства на цифровые устройства, генерирование случайных последовательностей и т.п. Отличительными особенностями ФНФ являются их случайность, непредсказуемость и невозпроизводимость, обусловленные неконтролируемыми, случайными вариациями исходных материалов и технологических процессов при их изготовлении. По своей сути ФНФ представляют собой цифровые схемы, позволяющие извлекать подобные вариации и преобразовывать их в двоичную форму для дальнейшего использования. Среди всего многообразия ФНФ выделяют ФНФ типа арбитр (АФНФ), которая представляет собой цифровую схему, которая принимает на входы двоичное значение N -разрядного запроса и вырабатывает однобитный ответ. Функционирование схемы АФНФ основано на сравнении времени прохождения двух копий тестового сигнала по паре конфигурируемых путей, выбранной значением запроса из множества $2N$ всех возможных пар. Результат сравнения и определяет двоичное значение ответа АФНФ. Множество всех пар запрос-ответ является случайным, непредсказуемым и невозпроизводимым в случае реализации копий схемы ФНФ как на одном, так и на других кристаллах, в том числе с использованием различных технологий. В данной статье предлагается новый подход к синтезу схем АФНФ, основанный на применении элементов перестановочных сетей и позволяющий формировать нелинейные конфигурации пар путей, что потенциально усложняет построение модели АФНФ с целью осуществления атаки на ее реализацию. Приводятся новые схемотехнические решения для построения АФНФ и результаты экспериментальных исследований их основных характеристик, полученных при реализации на FPGA серии Zynq-7000.

Ключевые слова: физически неклонируемая функция, арбитр, перестановочные сети.

Введение

Физически неклонируемые функции (ФНФ) представляют собой реализованные цифровые схемы, принимающие на свои входы значение запроса CH (*Challenge*) и вырабатывающие значение ответа R (*Response*) в качестве реакции на поданный запрос [1]. Формально поведение схемы ФНФ можно описать как отображение множества запросов на множество ответов: $PUF: CH \rightarrow R$, при этом $y = PUF(x)$ ($y \in R$, $x \in CH$), где функция PUF не известна и не определена до момента изготовления экземпляра схемы. При попытке изготовить идентичную копию схемы ФНФ, в том числе с применением иных технологий, происходит изменение множества R при использовании одного и того же множества CH . Другими словами идентичная копия будет иметь функцию $PUF' \neq PUF$, что определяет свойство уникальности (неклонируемости). При изготовлении схем физически невозможно создать две идентичные копии, имеющие одинаковые параметры и характеристики, вариации которых случайны и неконтролируемы. К таким параметрам можно отнести неоднородное распределение примесей в применяемых при изготовлении схем материалах, геометрические размеры используемых элементов и сигнальных линий и т.п. Перечисленные параметры непосредственно влияют на основные характеристики структурных элементов

цифровых устройств, такие как временные задержки распространения сигналов. Извлечение уникальных физических параметров и трансформация их в цифровое представление и есть основная задача проектирования схем ФНФ. Наиболее удачной схемой, позволяющей оценивать различия задержек распространения сигналов через симметричные пути цифровых устройств, является схема ФНФ типа арбитр (АФНФ) [1, 2].

Помимо уникальности к ФНФ предъявляют ряд других требований, среди которых можно выделить непредсказуемость, случайность и стабильность. Под непредсказуемостью можно понимать не возможность предсказать, смоделировать либо иным способом оценить значение функции $y' = PUF(x')$, при известном значении $y = PUF(x)$, $x' \neq x$. Среди многих характеристик, оценивающих случайность ФНФ выделяют единообразие, определяющее соотношение числа единичных $R1$ и нулевых ответов $R0$ на множестве уникальных запросов $CH \rightarrow R = \{R0, R1\}$. В идеальном случае $|R0| = |R1|$. Под стабильностью ФНФ понимают способность схемы к генерированию одинаковых ответов на многократно повторяемые запросы: $CH \rightarrow R^t$, $CH \rightarrow R^{t+1}$, ..., $CH \rightarrow R^{t+W}$, где R^t – множество ответов, полученное в дискретный отсчет времени t , W – число повторений. Для идеальной ФНФ $R^t = R^{t+1} = \dots = R^{t+W}$.

Исследователи и разработчики, осуществляющие модернизации существующих и разработку новых схем ФНФ, действуют в стремлении обеспечивать высокие показатели описанных выше свойств в зависимости от области применения и технологических ограничений. В данной работе рассматривается решение проблемы увеличения непредсказуемости ответов АФНФ путем построения нелинейных пар симметричных путей.

Классическая схема АФНФ

Физически неклонируемая функция типа арбитр (АФНФ) впервые была предложена в работе [2]. Структурно схема АФНФ состоит из трех основных блоков: генератора тестовых импульсов (ГТИ), блока симметричных путей (БСП) и арбитра (АРБ). Схема ГТИ, как правило, вырабатывает одиночный тестовый импульс s , две копии которого s^a и s^b одновременно поступают на два входа БСП a и b соответственно. Помимо этого, БСП имеет N -разрядный вход запроса $CH = [ch_0, ch_1, ch_2, \dots, ch_{N-1}] = [ch_0:ch_{N-1}]$, значение которого выбирает уникальную конфигурацию пары внутренних путей (p_0, p_1) , которые коммутируют два входа a и b с двумя выходами x и y : $(a, b) \rightarrow (p_0, p_1)^{CH} \rightarrow (x, y)$. В итоге на выходах появляются импульсы s^x и s^y , являющиеся копиями исходных s^a и s^b . В зависимости от значения запроса CH может происходить как прямая, так и обратная коммутация входов с выходами. Под путем, который

проходит одиночный импульс, будем понимать последовательность структурных элементов и соединительных линий, обеспечивающих связь между исходным входом и соответствующим выходом БСП. Для АФНФ крайне важно соблюдать симметричность (структурную идентичность) двух путей, по которым проходят две копии тестовых импульсов [1, 2].

После прохождения выбранных путей $(p_0, p_1)^{CH}$ тестовые импульсы s^x и s^y появляются на выходах БСП с различными значениями задержек $\delta(p_0^{CH})$ и $\delta(p_1^{CH})$, обусловленными технологически неконтролируемыми вариациями выбранных симметричных путей. Схема арбитра осуществляет сравнение значений $\delta(p_0^{CH})$ и $\delta(p_1^{CH})$ с выработкой бинарного значения ответа R^{CH} . Одной из наиболее используемых схем АРБ является схема синхронного D -триггера, на входы синхронизации и данных которого подаются сигналы с выходов БСП, при этом сравнению подвергаются передние фронты тестовых импульсов s^x и s^y [1]. В свою очередь сама схема БСП строится из последовательно подключенных базовых блоков α_i , $i \in [0, 2^N - 1]$, обеспечивающих прямую и перекрестную коммутацию сигналов с двух входов a_i и b_i на два выхода x_i и y_i . При $ch_i = 0$ осуществляется прямая коммутация $\alpha_i^0 ((a_i, b_i) \rightarrow (x_i, y_i))$, если $ch_i = 1$ – перекрестная коммутация $\alpha_i^1 ((a_i, b_i) \rightarrow (y_i, x_i))$. На рисунке 1 приведена общая структура классической схемы АФНФ с коммутационным элементом БСП, реализованным при помощи двух мультиплексоров m_{i0} и m_{i1} .




Рисунок 1. Структурная схема классической АФНФ (а), схема коммутационного элемента (б) и схема арбитра (в)

Рассмотрим пример структуры АФНФ для $N=2$. При этом БСП состоит из двух элементов α_0 и α_1 , а значение запроса $CH = [ch_0, ch_1]$ и определяет конкретную конфигурацию пары путей $(p_0, p_1)^{CH}$ из четыре возможных. Так, при $CH_0 = [00]$ (здесь и далее для произвольного запроса) конфигурируется следующая пара путей $(p_0, p_1)^0$: $\alpha_0^0 \rightarrow \alpha_1^0 = (m_{00}^0, m_{01}^0) \rightarrow (m_{10}^0, m_{11}^0)$, где m_{ij}^r обозначает часть пути, проходящего от r -го входа мультиплексора m_{ij} до его выхода $(r, j \in \{0, 1\})$. При $CH_3 = [11]$ пути для тестовых импульсов будут выглядеть следующим образом

$(p_0, p_1)^3$: $\alpha_0^1 \rightarrow \alpha_1^1 = (m_{01}^1, m_{00}^1) \rightarrow (m_{11}^1, m_{10}^1)$. В общем случае значение i -го бита запроса и определяет конфигурацию части пути, проходящего через элемент $\alpha_i^{ch_i} : (m_{i0}^{ch_i}, m_{i1}^{ch_i})$, где $\overline{ch_i}$ есть инверсное значение $ch_i \in \{0, 1\}$.

В обоих рассмотренных вариантах пары путей $(p_0, p_1)^0$ и $(p_0, p_1)^3$ являются симметричными, так как проходят через одинаковое число структурных однотипных элементов и соединительных проводников, незначительные уникальные отличия которых приводят к различным, непредсказуемым значениям $\delta(p_0^{CH})$ и $\delta(p_1^{CH})$, что в итоге влияет на конечный результат R^{CH} .

Как видно из представленного (рис. 1) БСП имеет линейную структуру последовательно соединенных блоков α_i , которые являются базовыми блоками перестановочных сетей (*permutation networks*) [3]. Линейная природа БСП классической схемы АФНФ является уязвимой к атакам, как правило осуществляемым методами машинного обучения, с целью создания точной модели, воспроизводящей значения множества ответов, идентичным ее физической реализации [4]. Для предотвращения подобных действий предлагается много подходов, среди которых можно выделить методы, нацеленные на нелинейном преобразовании значений запросов [5], что усложняет проведение атак на АФНФ.

В данной статье предлагается альтернативный подход к синтезу схем БСП на основе схемотехнических элементов перестановочных сетей, позволяющий формировать нелинейные комбинации пар путей для прохождения тестовых импульсов, что потенциально может усложнить последовательности вырабатываемых ответов.

Новые элементы блока симметричных путей

Введем следующие ограничения на построения новых элементов БСП, которые характерны в том числе и для классической схемы (см. рис. 1).

1. Минимальное число входов и выходов – два. Данное ограничение обусловлено применением одной пары конфигурируемых путей и одного арбитра.

2. Пара путей во всех конфигурациях элемента должна быть симметричной. Это означает, что произвольно выбранные пути должны проходить через одинаковое число однотипных элементов и

сигнальных линий. В противном случае сильная асимметрия путей может приводить к заведомо постоянному значению ответа R .

3. На выходах произвольной пары путей должны наблюдаться как прямая, так и перекрестная коммутация входных сигналов.

Пусть $P^{k,k}$ есть перестановочная сеть, обеспечивающая все возможные $k!$ коммутации k входов с k выходами. Очевидно, что $P^{2,2} = \alpha$, удовлетворяющая описанным выше требованиям. Введем нотацию, позволяющую описывать последовательную линейную структуру классической схемы БСП на основе таких элементов: $\{P_0^{2,2}, P_1^{2,2}, P_2^{2,2}, \dots, P_{N-1}^{2,2}\} = \{\alpha_0, \alpha_1, \alpha_2, \dots, \alpha_{N-1}\}$; и сокращенную нотацию: $\{P^{2,2}\}^N = \{\alpha\}^N$, где N это число идентичных элементов, последовательно соединенных друг с другом.

Первым предлагаемым структурным элементом БСП будет являться элемент перестановочной сети $P^{2,k} = \beta^k$, обеспечивающий прямую и перекрестную коммутацию двух своих входов с произвольной парой из k имеющихся выходов. Для $k=2$ элемент β^2 эквивалентен элементу α . Для произвольного значения k необходимо и достаточно k конфигураций, удовлетворяющих вышеописанному условию. На рисунке 2 приведены графические обозначения элементов β^k , β^4 и структурная схема элемента β^4 , построенная на двух элементах α .

Приведенная схема является одной из возможных, которая удовлетворяет описанным требованиям и имеет четыре конфигураций, которые обеспечивают прямую и перекрестную коммутацию входов (a_i, b_i) с произвольной парой выходов из четырех возможных (w_i, x_i, y_i, z_i) .




Рисунок 2. Графическое обозначение элемента β^k (а), элемента β^4 (б) и структурная схема элемента β^4 (в)

Схемотехническую реализацию перестановочной сети $P^{k,k}$ для произвольного значения k обозначим как элемент γ^k , обладающий k входами и k выходами и позволяющий осуществлять число возможных коммутаций близкое к $k!$. Например, для $k=4$ элемент γ^4 может быть построен на

основе пяти элементов α [3]. На рисунке 3 представлена модифицированная схема элемента γ^4 , которая содержит дополнительный элемент α_{i5} с фиксированным значением бита запроса, необходимый для обеспечения топологической симметрии путей.




Рисунок 3. Графическое обозначение элемента γ^k (а), элемента γ^4 (б) и структурная схема элемента γ^4 (в)

В случае отсутствия элемента α_5 фронты тестовых сигналов на выходах y_i и z_i могут заведомо быстрее формироваться в сравнении с сигналами на выходах w_i и x_i . Для представленного элемента существует 32 конфигурации внутренних путей, 24 из которых приводят к всевозможным коммутациям входов (a_i, b_i, c_i, d_i) с выходами (w_i, x_i, y_i, z_i). Восемь значений запроса $CH = [ch_i : ch_{i+4}]$ приводят к одинаковому значению на выходах схемы, однако с использованием различных конфигураций внутренних путей. Например, при подаче запросов $CH_{16} = [10000]$ и $CH_1 = [00001]$ на выходах схемы будет наблюдаться одна и та же комбинация значений входных сигналов (b_i, a_i, c_i, d_i). При этом два пути, связывающие входы c_i и d_i с выходами y_i и z_i останутся неизменными, а пути, связывающие входы a_i и b_i с выходами w_i и x_i , будут разными: для CH_{16} это пара путей $a_i \rightarrow \alpha_0^0 \rightarrow \alpha_3^0 \rightarrow \alpha_4^0 \rightarrow x_i$ и $b_i \rightarrow \alpha_1^0 \rightarrow \alpha_2^0 \rightarrow \alpha_4^0 \rightarrow w_i$, а для CH_1 это пути $a_i \rightarrow \alpha_0^0 \rightarrow \alpha_2^0 \rightarrow \alpha_4^1 \rightarrow x_i$ и $b_i \rightarrow \alpha_1^0 \rightarrow \alpha_3^0 \rightarrow \alpha_4^1 \rightarrow w_i$.

Данный пример показывает возможность использования дополнительного бита запроса ch_{i+5} , управляющего элементом α_5 , что в свою очередь обеспечивает 64 уникальные конфигурации внутренних путей элемента γ^4 .

Элементом обратным β^k будет являться перестановочная сеть $P^{k,2} = \delta^k$, осуществляющую прямую и перекрестную коммутацию произвольной пары из k входов с двумя выходами. Подобный элемент может быть синтезирован на основе C_k^2 мультиплексоров 2×1 , коммутирующих две двухразрядные шины с одной выходной двухразрядной шиной, и одного элемента α . На рисунке 4 приведен пример структуры элемента δ^4 , состоящего из шести двухразрядных мультиплексоров $m_{i0} - m_{i5}$ и одного элемента α_{i0} , обеспечивающего 16 конфигураций внутренних путей, которые обеспечивают прямую и перекрестную коммутацию произвольной пары из четырех входов (a_i, b_i, c_i, d_i) с двумя выходами (x_i, y_i).




Рисунок 4. Графическое обозначение элемента δ^k (а), элемента δ^4 (б) и структурная схема элемента δ^4 (в)

Для приведенного элемента δ^4 существует 12 уникальных конфигураций, при которых на двух выходах (x_i, y_i) появятся все возможные комбинации двух различных символов из входного набора (a_i, b_i, c_i, d_i) . Четыре значения запроса $CH = [ch_i:ch_{i+3}]$ приводят к одинаковым значениям на выходах схемы, но при этом активируются различные пары путей. Так, два запроса $CH_{10} = [1010]$ и $CH_{12} = [1100]$ приведут к появлению на выходах (x_i, y_i) одного и того же значения (b_i, c_i) . При подаче запроса CH_{10} будет активирован путь для пары тестовых импульсов $(b_i, c_i) \rightarrow m_{i1}^1 \rightarrow m_{i4}^0 \rightarrow m_{i5}^1 \rightarrow \alpha_{i0}^0 \rightarrow (x_i, y_i)$, а при запросе $(b_i, c_i) \rightarrow m_{i1}^1 \rightarrow m_{i3}^1 \rightarrow m_{i5}^0 \rightarrow \alpha_{i0}^0 \rightarrow (x_i, y_i)$ (рис. 4, в). Таким образом, все возможные 16 конфигураций δ^4 элемента будут являться уникальными для произвольной пары путей.

Построение БСП на предложенных элементах

Рассмотренные элементы могут быть использованы в различных сочетаниях для построения БСП. Рассмотрим некоторые из вариантов сочетаний элементов $\alpha, \beta^k, \gamma^k, \delta^k$ для $k = 4$. Так, выходы элемента α могут быть сопряжены со входами элемента β^4 , выходы β^4 – со входами элементов γ^4 и δ^4 , выходы γ^4 – со входами элементов γ^4 и δ^4 , выходы δ^4 – со входами элемента α . Даже такие простые примеры сочетаний позволяют конструировать БСП многими способами. В таблице 1 приведены описания некоторых шаблонных структур БСП.

Таблица 1

Примеры различных конфигураций БСП для $k = 4$

№	Символьное описание БСП	Разрядность запроса CH
1	$\{\alpha\}^e$	e
2	$\{\beta^4\delta^4\}^e$	$6e$
3	$\{\alpha\}^e\{\beta^4\delta^4\alpha\}^g$	$7g+e$
4	$\{\alpha\}^e\beta^4\{\gamma^4\}^g\delta^4\{\alpha\}^h$	$5g+e+h+6$
5	$\{\{\alpha\}^e\{\beta^4\delta^4\}^g\{\alpha\}^h\}^q$	$q(6g+e+h)$

Применяя целочисленные значения коэффициентов e, g, h, q и k можно синтезировать структуру БСП с различной разрядностью запроса CH . На рисунке 5 приведены примеры двух структур (№ 3 и № 4, см. табл. 1) с размерностью запроса равной 16. Данные структуры являются одномерными, построенными последовательным соединением элементов α, β, γ и δ , и обладающие различной структурной сложностью. Так, если классическая схема БСП для $N = 16$ $\{\alpha\}^{16}$ состоит из 32 мультиплексоров, то схема на рис. 1 а – из 44 мультиплексоров, а схема на рис. 1 б – из 40 мультиплексоров. Увеличенная структурная сложность вместе с неоднородностью БСП может потенциально усложнить связь подаваемых запросов с генерируемыми ответами АФНФ.




Рисунок 5. Структуры БСП, сформированные по следующим символьным описаниям: $\{\alpha\}^2\{\beta^4\delta^4\alpha\}^2$ (а), $\{\alpha\}^3\beta^4\gamma^4\delta^4\{\alpha\}^2$ (б)

Для еще большего увеличения структурной сложности и с учетом требования симметрии всех пар выбираемых путей возможно построение многомерных структур БСП с использованием разнообразных сочетаний базовых элементов, например:

$$\alpha\beta^k \left\{ \begin{matrix} \alpha_0 \\ \dots \\ \alpha_{k-1} \end{matrix} \right\}^e \left\{ \gamma^k \right\}^g \left\{ \begin{matrix} \delta_0^{k/2} \\ \delta_1^{k/2} \end{matrix} \right\} \delta^4.$$

Для оценки нелинейности БСП, сформированных на основе предложенных элементов, проведем анализ значений $\delta(p_0^{CH})$ и $\delta(p_1^{CH})$ в зависимости от множества различных запросов CH .

Экспериментальное исследование характеристик различных реализаций АФНФ

Для исследования схемных реализаций АФНФ была использована плата быстрого прототипирования *Digilent ZYBO Z7* с программируемой логической интегральной схемой *FPGA Xilinx ZYNQ* [6]. Исследованию подверглись три реализации АФНФ для $N = 32$, БСП которых имеют следующие описания: BSP1: $\{\alpha\}^{32}$, BSP2: $\{\alpha\}^4\{\beta^4\delta^4\alpha\}^4$ и BSP3: $\alpha\beta^4\{\gamma^4\}^5\delta^4$. Проектирование схем АФНФ было осуществлено при помощи языка *VHDL* и САПР цифровых устройств *Xilinx Vivado/Vitis*. На кристалле *FPGA* было реализовано четыре идентичных схемы для каждого типа

БСП. Кроме этого, дополнительно были реализованы управляющие схемы и схемы, позволяющие измерять значения $\delta(p_0^{CH})$ и $\delta(p_1^{CH})$. Управление передачей данных, генерирование значений запроса было осуществлено программным способом при помощи встроенного в *FPGA* процессора *ARM Cortex-A9*. Вычисление результирующего значения ответа АФНФ производилось на рабочей станции на основе собранных данных в процессе экспериментов.

В ходе технологического синтеза была оценена структурная сложность каждого из вариантов БСП, которая оценивалась в количестве *LUT*-блоков кристалла *FPGA*. Сложность классической схемы BSP1 составила 64 блока, для BSP2 – 88 блоков и для BSP3 – 80 блоков.

В первом эксперименте вычислялись значения $\Delta_{CH}^f = \delta(p_0^{CH}) - \delta(p_1^{CH})$ для $K = 10^4$ уникальных запросов *СН*, полученных генератором *M*-последовательностей, где $f \in [0, 3]$ является индексом исследуемой схемы. На рисунке 6 приведены графики отсортированных значений Δ_{CH}^f , полученных на одном кристалле *FPGA* для трех описанных выше конфигураций БСП. Графики также содержат данные о диапазонах изменения значений Δ_{CH}^f и о параметре *Asym*, являющийся среднеквадратичным значением математических ожиданий $\mu(\Delta_{CH}^f), \forall f \in [0, 3]$.

Последний параметр может быть использован для оценки степени асимметрии множеств значений Δ_{CH}^f , что непосредственно влияет на мощность подмножеств нулевых и единичных ответов АФНФ.




Рисунок 6. Графики значений Δ_{CH}^f для различных модификаций БСП: BSP1 (а), BSP2 (б), BSP3 (в)

Как видно, нелинейная природа значений задержек ярко выражена для BSP2, которая также обладает меньшим значением *Asym* (0,0162 нс) (рис. 6 б), а большей (0,47127 нс) – классическая реализация БСП (рис. 6 а). Увеличение структурной сложности, в том числе, повлияло на диапазон разброса значений Δ_{CH}^f , который для BSP2 уменьшился на 18,18 %, а для BSP3 – на 41,8 % в сравнении с классической схемой. Помимо этого, были вычислены усредненные значения среднеквадратичных отклонений $\sigma\Delta_{CH}^f$. Для схемы BSP1 этот показатель равен 2,2642 нс, для BSP2 – 1,3925 нс, и для BSP3 – 1,3145 нс.

Полученные результаты можно объяснить более плотной компоновкой структурных элементов схемных реализаций BSP2 и BSP3, что привело к уменьшению числа протяженных соединительных линий, которые, как известно, вносят значительную асимметрию в сравнении со структурными элементами БСП при их реализации на *FPGA* [7].

Другим примером, подтверждающим степень нелинейности значений задержек, может служить графический тест «Случайное двумерное блуждание» [8], приведенный для схемы $f = 1$ (рис. 7).



Рисунок 7. Результаты графического теста для схемы $f=1$: BSP1 (а), BSP2 (б), BSP3 (в)

Помимо графических иллюстраций оценим нелинейность рассматриваемых схем БСП при помощи теста на линейную сложность [9], в основе которого лежит алгоритм Берлекэмпа-Мэсси [10]. В таблице 2 приведены значения уровня значимости (P -value), вычисляемого в ходе реализации описанного теста, большее значение которого свидетельствует о большей линейной сложности последовательности данных, полученных на выходах исследуемых схем БСП.

Как видно из данных, представленных в таблице 2, последовательности ответов для схем BSP2 и BSP3 обладают большей нелинейностью в сравнении с классической реализацией БСП АФНФ.

Таблица 2

Результаты теста на линейную сложность (значения P -value)

Тип БПС	Индекс схемы, f				Среднее
	0	1	2	3	
BSP1	0.2237	0.2608	0.3694	0.1125	0.2416
BSP2	0.8453	0.6360	0.7960	0.5565	0.7084
BSP3	0.8683	0.7170	0.4842	0.8793	0.7372

Проведем оценку одних из основных характеристик схемных реализаций ФНФ как единообразия Un (соотношение единичных и нулевых ответов), U_{intra} – внутикристалльная уникальность (степень различия множества пар запрос-ответ для копий ФНФ, реализованных на одном кристалле) и St – стабильность (удельное значение многократно повторяющихся запросов, при которых наблюдаются стабильные ответы) [11]. Все перечисленные характеристики вычислялись на описанном выше наборе уникальных запросов и нормированы в диапазоне $[0,1]$ от худшего к наилучшему значению (табл. 3).

Таблица 3

Значения характеристик АФНФ с различными схемами БСП

Тип БПС	Un	U_{intra}	St
BSP1	0.8416	0.8151	0.9920
BSP2	0.9918	0.6697	0.9952
BSP3	0.9202	0.9008	0.9975

Как видно из приведенных данных рассмотренные модификации БСП обладают сравнимыми, а иногда и превосходящими, значениями основных характеристик ФНФ по отношению к классической схеме БСП. Меньшая степень асимметрии множества значений Δ'_{CH} для BSP2 и BSP3 (рис. 6) подтвердилась на полученных значениях единообразия Un .

Заключение

В данной статье были предложены схемотехнические модификации блока симметричных путей физически неклонированной функции типа арбитр, основанные на реализации элементов перестановочных сетей. Усложнение базовых элементов БСП привело к увеличению линейной сложности последовательности ответов, что потенциально затрудняет построение математической модели АФНФ с целью осуществления атак на ее реализацию. Рассмотренные новые базовые элементы БСП могут быть применены для построения более сложных структур АФНФ. Как показали проведенные экспериментальные исследования предложенные модификации БСП обладают лучшими показателями единообразия и сравнимыми значениями стабильности по отношению к классической схеме АФНФ.

ЛИТЕРАТУРА

1. **Ярмолик, В.Н.** Физически неклонированные функции / В.Н. Ярмолик, Ю.Г. Вашинко // Информатика. – 2011. – № 2 (30). – С. 92-103.
2. **Gassend, B.** Silicon physical random functions / B. Gassend [et al.] // Proc. of 9th Computer and Communications Security Conf. (CCS'02), Washington, DC USA, 18–22 Nov. 2002. – Washington, 2002. – P. 148-160.
3. **Waksman, A.** A Permutation Network / A. Waksman // Journal of the ACM. – 1968. – №1(15). – P. 159-163.
4. **Santikellur, P.** Deep Learning based Model Building Attacks on Arbiter PUF Compositions / P. Santikellur, A. Bhattacharyay, R.S. Chakraborty // IACR Cryptol. ePrint Arch. – 2019. – 10 p. – (Preprint / Paper 2019/566).
5. **Zhang, J.** Set-Based Obfuscation for Strong PUFs Against Machine Learning Attacks / J. Zhang, C. Shen // IEEE Transactions on Circuits and Systems I: Regular Papers. – 2021. – № 1(68). – P. 288-300.
6. **ZyboZ7: Zynq-7000 ARM/FPGA SoC Development Board** [Electronic resource]. – Mode of access: <https://digilent.com/reference/programmable-logic/zybo-z7/start>. – Date of access: 19.01.2023.
7. **Morozov, S.** An Analysis of Delay Based PUF Implementations on FPGA / S. Morozov, A. Maiti, P. Schaumont // Proc. of International Symposium on Applied Reconfigurable Computing: Tools and Applications (ARC 2010), Los Angeles, CA, US, 25–27 Mar. 2010. – Los Angeles, 2010. – P. 382-387.
8. **Costa, L.F.** Exploring complex networks through random walks [Electronic resource] / L.F. Costa, G. Travieso. – Physical Review E, 2007. – Mode of access: <https://arxiv.org/pdf/physics/0604193.pdf>. – Date of access: 19.01.2023.
9. **Rukhin, A.** A Statistical Test Suite for Random and Pseudorandom Number Generators for Cryptographic Applications [Electronic resource] / A. Rukhin [et al.] – NIST Special Publication 800-22, 2010. – Mode of access: <https://www.nist.gov/publications/statistical-test-suite-random-and-pseudorandom-number-generators-cryptographic>. – Date of access: 19.01.2023.
10. **Martin-Navarro, J.L.** Review of the Lineal Complexity Calculation through Binomial Decomposition-Based Algorithms / J.L. Martin-Navarro, F.S. Amparo // Mathematics. – 2021. – №5 (9) – P. 1-22.
11. **Maiti, A.** A Systematic Method to Evaluate and Compare the Performance of Physical Unclonable Functions / A. Maiti, V. Gunreddy, P. Schaumont. In: Athanas, P., Pnevmatikatos, D., Sklavos, N. (eds.) Embedded Systems Design with FPGAs. Springer, New York, NY, 2013. – P. 245-267.

REFERENCES

1. **Yarmolik, V.N.** Fizicheski nekloniruemye funkicii / V.N. Yarmolik, Yu.G. Vashinko // Informatika. – 2011. – № 2(30). – PP. 92-103.
2. **Gassend, B.** Silicon physical random functions / B. Gassend [et al.] // Proc. of 9th Computer and Communications Security Conf. (CCS'02), Washington, DC USA, 18–22 Nov. 2002. – Washington, 2002. – PP. 148-160.
3. **Waksman, A.** A Permutation Network / A. Waksman // Journal of the ACM. – 1968. – № 1(15). – Pp. 159-163.
4. **Santikellur, P.** Deep Learning based Model Building Attacks on Arbiter PUF Compositions / P. Santikellur, A. Bhattacharyay, R.S. Chakraborty // IACR Cryptol. ePrint Arch. – 2019. – 10 p. – (Preprint / Paper 2019/566).
5. **Zhang, J.** Set-Based Obfuscation for Strong PUFs Against Machine Learning Attacks / J. Zhang, C. Shen // IEEE Transactions on Circuits and Systems I: Regular Papers. – 2021. – № 1(68). – Pp. 288-300.
6. **ZyboZ7: Zynq-7000 ARM/FPGA SoC Development Board** [Electronic resource] . – Mode of access: <https://digilent.com/reference/programmable-logic/zybo-z7/start>. – Date of access: 19.01.2023.
7. **Morozov, S.** An Analysis of Delay Based PUF Implementations on FPGA / S. Morozov, A. Maiti, P. Schaumont // Proc. of International Symposium on Applied Reconfigurable Computing: Tools and Applications (ARC 2010), Los Angeles, CA, US, 25–27 Mar. 2010. – Los Angeles, 2010. – P. 382–387.
8. **Costa, L.F.** Exploring complex networks through random walks [Electronic resource] / L.F. Costa, G. Travieso. – Physical Review E, 2007. – Mode of access: <https://arxiv.org/pdf/physics/0604193.pdf>. – Date of access: 19.01.2023.
9. **Rukhin, A.** A Statistical Test Suite for Random and Pseudorandom Number Generators for Cryptographic Applications [Electronic resource] / A. Rukhin [et al.] – NIST Special Publication 800-22, 2010. – Mode of access: <https://www.nist.gov/publications/statistical-test-suite-random-and-pseudorandom-number-generators-cryptographic>. – Date of access: 19.01.2023.
10. **Martin-Navarro, J.L.** Review of the Lineal Complexity Calculation through Binomial Decomposition-Based Algorithms / J.L. Martin-Navarro, F.S. Amparo // Mathematics. – 2021. – № 5(9) – Pp. 1-22.
11. **Maiti, A.** A Systematic Method to Evaluate and Compare the Performance of Physical Unclonable Functions / A. Maiti, V. Gunreddy, P. Schaumont. In: Athanas, P., Pnevmatikatos, D., Sklavos, N. (eds.) Embedded Systems Design with FPGAs. Springer, New York, NY, 2013. – Pp. 245-267.

IVANIUK A.A., SHAMYNA A.YU.

PHYSICALLY NON-CLONEABLE ARBITER -TYPE FUNCTION WITH NON-LINEAR PATH PAIRS

*Belarusian state University of Informatics and Radioelectronics
Minsk, Republic of Belarus*

Physically unclonable functions (PUFs) are basic physical cryptographic primitives, providing to solve tasks such as unclonable identification, digital device authentication and copyright authentication, true random sequence generation, etc. The major features of PUFs are stability, unpredictability and irreproducibility, due to uncontrollable random variations of distinctive features of the raw materials and technological processes used during their manufacturing. Generally, PUF are digital circuits that extract such variations and convert them into a binary format, which applied for further use. Among the variety of PUF types, an Arbiter PUF (APUF) is distinguished, which is a digital circuit with N -bit challenge input and single output for one-bit response generation. The functionality of APUF is based on comparison of transition time of two copies of the test signal along a pair of configurable paths, selected by the challenge value CH from a set of $2N$ all possible pairs. The result of the comparison is the binary value of the response. The set of all challenge-response pairs is a random, unpredictable and irreproducible in the cases of implementation of cloned PUF circuits both on single and/or on another chips, also using different technologies. This article presents a new approach to the synthesis of the APUF circuits, based on the permutation network elements, which allow to construct the nonlinear structures of pair of paths. This implies the potential complication of building an APUF model to attack its implemented instances. This article presents new schematic solutions for the synthesis of APUF circuits. Also, the main characteristics of the proposed APUF circuits implemented on the Xilinx Zynq-7000 FPGA is analyzed.

Keywords: physically unclonable functions, arbiter, permutation networks.



Иваниук Александр Александрович, доктор технических наук, доцент, профессор кафедры информатики БГУИР, заведующий совместной учебной лабораторией «СК хайникс мемори солоушнс Восточная Европа». Сфера научных интересов: физическая криптография, контролепригодное проектирование средств вычислительной техники. Автор более 150 научных работ и 8 патентов.

Alexander A. Ivaniuk, doctor of sciences, associated professor, professor at computer science department at the Belarusian State University of Informatics and Radioelectronics, head of the joint educational laboratory "SK hynix memory solutions Eastern Europe". Research interests: physical cryptography, digital design and design for testability. He has published over 150 scientific articles and 8 patents.

E-mail: ivaniuk@bsuir.by



Шамына Артем Юрьевич, магистр технических наук, старший преподаватель кафедры ПОИТ БГУИР. Сфера научных интересов физическая криптография.

Artem Yu. Shamyna, Master of Engineering sciences, Senior Lecturer at the Belarusian State University of Informatics and Radioelectronics". Research interests: physical cryptography

E-mail: shamyna@bsuir.by