САНКТ-ПЕТЕРБУРГСКИЙ ГОСУДАРСТВЕННЫЙ ЭЛЕКТРОТЕХНИЧЕСКИЙ УНИВЕРСИТЕТ «ЛЭТИ» им. В.И. Ульянова (Ленина)

ПАВЛОВСКИЙ ЦЕНТР «ИНТЕГРАТИВНАЯ ФИЗИОЛОГИЯ - МЕДИЦИНЕ, ВЫСОКОТЕХНОЛОГИЧНОМУ ЗДРАВООХРАНЕНИЮ И ТЕХНОЛОГИЯМ СТРЕССОУСТОЙЧИВОСТИ»

ИНСТИТУТ ФИЗИОЛОГИИ им. И.П. Павлова РОССИЙСКОЙ АКАДЕМИИ НАУК

IEEE

РОССИЙСКАЯ СЕВЕРО-ЗАПАДНАЯ СЕКЦИЯ IEEE

NEURONT.ETU.RU

IV МЕЖДУНАРОДНАЯ КОНФЕРЕНЦИЯ ПО НЕЙРОННЫМ СЕТЯМ И НЕЙРОТЕХНОЛОГИЯМ

16 июня 2023

NeuroNT'23

СБОРНИК ДОКЛАДОВ

Санкт-Петербург, 2023

Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» им. В.И. Ульянова (Ленина) (СПбГЭТУ «ЛЭТИ»)

Павловский центр «Интегративная физиология – медицине, высокотехнологичному здравоохранению и технологиям стрессоустойчивости»

Институт физиологии им. И.П. Павлова Российской академии наук (ИФ РАН)

Российская Северо-Западная секция Международного института инженеров электротехники и электроники IEEE

IV МЕЖДУНАРОДНАЯ КОНФЕРЕНЦИЯ ПО НЕЙРОННЫМ СЕТЯМ И НЕЙРОТЕХНОЛОГИЯМ

(NeuroNT'2023)

16 июня 2023 года

Сборник докладов

Санкт-Петербург
2023

УДК 004.032.26

ISBN 978-5-7629-3205-9

IV Международная конференция по нейронным сетям и нейротехнологиям (NeuroNT'2023): сб. докладов. СПб.: СПбГЭТУ «ЛЭТИ». 2023. – 115 с.

Международный программный комитет

Почетный председатель	Проф. Ханнес Топфер (Германия)
Сопредседатели	Проф. М.С. Куприянов (СПбГЭТУ «ЛЭТИ», Россия)
	Проф. Ю.Е. Шелепин (ИФ РАН, Россия)
Члены международного программного комитета	Dr. S.P. Shiva Prakash, Associate Professor, Department of Information Science and Engineering, JSS Science and Technology University, Mysuru, Karnataka, India
	Dr. Balaraman Ravindran, Prof., Computer Science and Engineering & Robert Bosch Centre for Data Science and AI, Indian Institute of Technology Madras, Chennai, Tamil Nadu, India
	Dr. Thanh Nghi Nguyen, Prof., Head of the Department of Physics and Mathematics, Hanoi University of Technology, Vietnam
	Dr. Nigel Foreman, Prof., Middlesex university, Department of Psychology, London, UK
	Проф. Ю.А. Шичкина (СПбГЭТУ «ЛЭТИ», Россия)
	Доц. М.М. Заславский (СПбГЭТУ «ЛЭТИ», Россия)
	Проф. В.О. Полякова (СПбГУ, Россия)
	Доц. О.И. Буренева (СПбГЭТУ «ЛЭТИ», Россия)
	Доц. О.Л. Петросян (СПбГУ, Россия)
	Проф. С.А. Вакуленко (ИПМаш РАН, Россия)
	Доц. М.П. Чмелевский (ФГБУ «НМИЦ им. В.А. Алмазова», Россия)
	Доц. Е.А. Пустозеров (СПбГЭТУ «ЛЭТИ», Россия)
	Проф. О.В. Войцеховская (ФГБУН Ботанический институт им. В.Л. Комарова РАН, Россия)
	Р.О. Малашин, (ИФ РАН, Россия)
	Е.Ю. Шелепин (ИФ РАН, Россия)

Организационный комитет

Председатель	Проф. В.А. Тупик (СПбГЭТУ «ЛЭТИ», Россия)
Члены организационного комитета	Доц. Я.А. Бекенева (СПбГЭТУ «ЛЭТИ», Россия)
	Проф. А.С. Красичков (СПбГЭТУ «ЛЭТИ», Россия)
	Доц. А.Ю. Горяева (СПбГЭТУ «ЛЭТИ», Россия)
	О.Н. Журавлева (СПбГЭТУ «ЛЭТИ», Россия)
	Н.В. Шевская (СПбГЭТУ «ЛЭТИ», Россия)
	К.Ф. Котченко (ИФ РАН, Россия)
	А.А. Бойко (ИФ РАН, Россия)

ISBN 978-5-7629-3205-9

© СПбГЭТУ «ЛЭТИ», 2023

Объяснительный искусственный интеллект в системах поддержки принятия врачебных решений

Е. Н. Волков, А. Н. Аверкин
Государственный университет «Дубна»
envolkoff@gmail.com

Аннотация. **Развитие современной медицины и постепенный переход к концепции Здравоохранения 5.0 (Healthcare 5.0) предполагает повышение роли автоматизированных систем поддержки принятия врачебных решений (СППВР) в процессах постановки диагноза и назначения лечения. Однако, несмотря на перспективы использования искусственных нейронных сетей в СППВР, существует проблема «непрозрачности» – невозможности понимания причин получения результатов, что недопустимо для систем такого рода. Применение объяснительного искусственного интеллекта в СППВР повышает уровень доверия к технологии. В исследовании проведён анализ современного состояния использования объяснительного искусственного интеллекта в СППВР.**

Ключевые слова: искусственный интеллект, объяснительный искусственный интеллект, медицинские системы, системы поддержки принятия решения, СППВР, здравоохранение, медицина, персонализированная медицина, экспертные систем, объяснительный искусственный интеллект, XAI

I. Введение

В последнее десятилетие использование искусственного интеллекта в медицинских исследованиях и общественном здравоохранении набирает обороты. Медицинские системы на основе искусственного интеллекта применяются для как анализа снимков при лучевой диагностике, так при выборе тактики лечения и ведении клинических записей. Потенциал использования искусственного интеллекта в медицине сложно недооценить. Более того, процесс перехода к концепции Здравоохранение 5.0 (Healthcare 5.0) предполагает использование решений на основе искусственного интеллекта, в том числе, для построения индивидуальной траектории наблюдения и, при необходимости, лечения, что говорит о переходе к эпохе персонализированной медицины. [10]

Одним из инструментов, призванных оптимизировать работу врача и медицинского персонала, является система поддержки принятия врачебных решений (от англ. Clinical Decision Support System). Такие системы обычно основаны на использовании классических методов машинного обучения, однако, благодаря высокому распространению искусственных нейронных сетей наметился сдвиг в их сторону. В то же время, из-за непрозрачности ИНС появляется необходимость использования методов объяснительного искусственного интеллекта (от англ. eXplainable Artificial Intelligence (XAI)).

II. Методы

A. *Поиск литературы*

Поиск публикаций по теме исследования осуществлялся с помощью формирования запросов, по ключевым словам, в библиографических базах PubMed, IEEE Digital Library, Google Scholar, eLIBRARY. В дальнейшем, для включения исследований в работу они должны были соответствовать следующим критериям:

1. Описана разработка конкретной СППВР или программного модуля с функциями СППВР;
2. Должна иметься описание применения методов XAI относительно выполняемых СППВР задач;
3. СППВР должна основываться на использовании искусственных нейронных сетей.

В исследование не включались обзоры литературы и публикации, не содержащие описания конкретной СППВР. Временной промежуток для включения публикаций в исследование: с 2018 по 2023 год. Результаты индексирования источников и включения в исследование представлены на рис. 1.

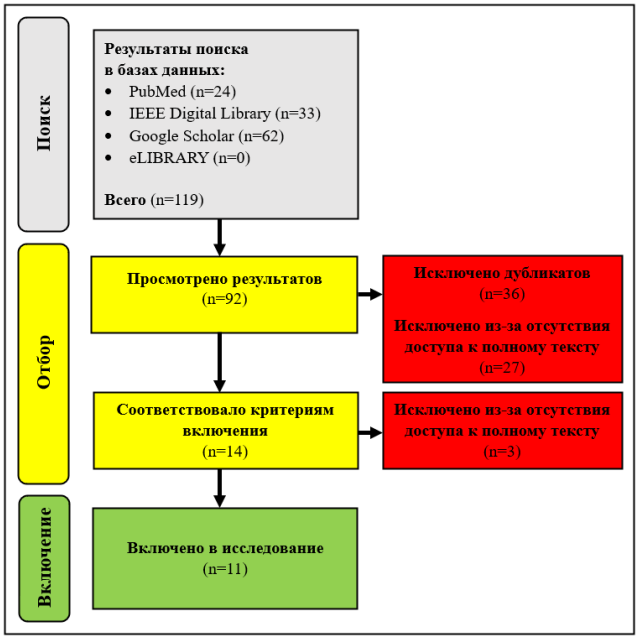

Рис. 1. Алгоритм поиска и отбора литературы для включения в исследование

Всего было найдено 119 публикаций, из них в исследование включено 11 работ, что обусловлено более строгими критериями включения, чем в

предшествующих систематических обзорах Xu Q. [14] (n=20) и Sheu R. [11] (n=5). Распределение публикаций по годам представлено на рис. 2. Отметим, что публикаций ранее 2018 года проиндексировано не было – это, в целом, соотносится со временем появления первых методов XAI.

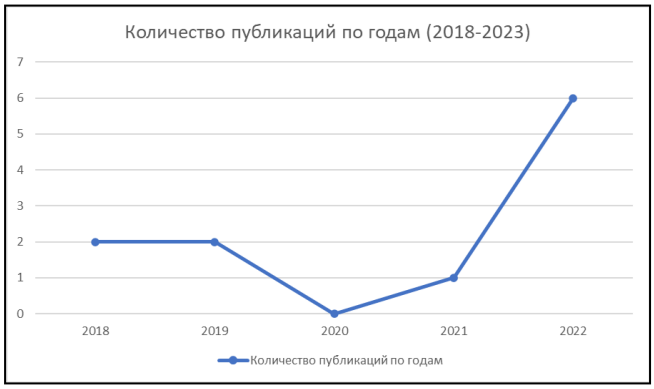

Рис. 2. Распределение публикаций по годам

B. *Системы поддержки принятия решений в медицине*

Система поддержки принятия врачебных решений (СППВР) – это программное решение, используемое врачами и иными медицинским специалистам в процессе принятия клинических решений. Традиционно, СППВР представляют собой систему, использующие клинические записи отдельного пациента, базу знаний (knowledge based) или базу данных (non-knowledge based) для выработки решения с помощью методов машинного или глубокого обучения (рис. 3). [12]

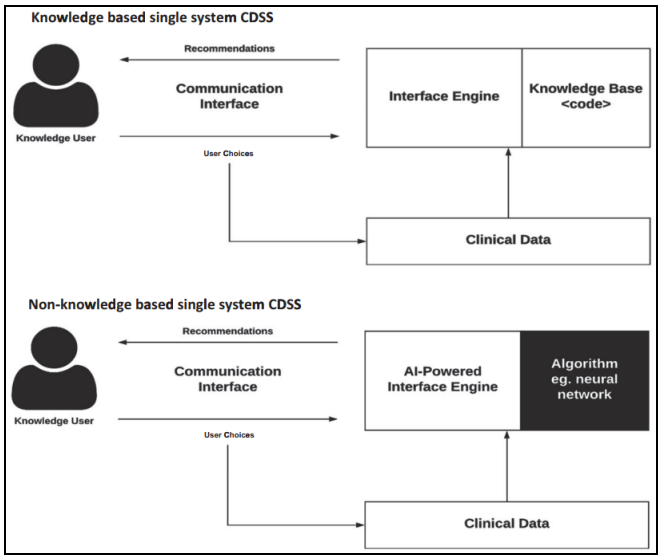

Рис. 3. «Знаниевые» и «незнаниевые» СППВР из исследования Sutton R. [12]

C. *Объяснительный искусственный интеллект и методы объяснения результатов*

Объяснительный искусственный интеллект является отличительной чертой третьего поколения искусственного интеллекта, и представляет собой набор методов объяснения результатов работы моделей машинного обучения, призванных повысить доверие пользователей за счёт вывод объяснений с помощью отдельного интерфейса. [2]

Методы XAI позволяют получить представление о том, почему модель машинного бучения получила то или иное решение без возможности отследить его полный алгоритм. Различают множество методов XAI относительно типа объяснения, данных, алгоритмов работы. [1]

III. Обзор исследований

Несмотря на большое распространение публикаций по тематике использования XAI в отдельных медицинских исследованиях, описание возможностей его применения в СППВР встречается не часто. Нами было найдено лишь два систематических обзора литературы по данной теме [11, 14], включающих в себя в общей сложности описание и систематизацию в общей сложности 25 оригинальных исследований.

Наиболее полно состояние использование методов объяснения результатов в СППВР представление в исследовании Xu Q. [14]. Автором было отобрано 20 исследований из баз данных Scopus, PubMed, Web of Science, Science Direct, Cochrane для включения в обзор. В качестве методов ML и DL в работах применялись: регрессия (n=5), деревья решений и случайный лес (n=4), байесовские методы (n=3), KNN (n=3), SVM (n=2), нечёткая логика (n=2), нейросети (n=3).

IV. Результаты и обсуждение

Среди отобранных работ (n=11) большая часть (n=4) оказалась посвящена обработке результатов лучевой диагностики (КТ/МРТ/рентген) [3, 4, 15, 17], в сфере офтальмологии также представлено несколько исследований (n=3) [6, 9, 13]. Отдельное место занимают исследования, посвящённые созданию решений СППВР для прогнозирования исходов терапии больных (n=2) [5, 16]. Стоит отметить, что из включённых публикаций только две являются полноценным описанием созданных и апробированных в реальной клинической практике СППВР [7, 8]. Описание решений и сравнительные характеристики представлены в табл. I.

Количество работ по созданию решений СППВР в сфере лучевой диагностики, во-многом, объясняется актуальностью применению неинвазивных методов исследования в диагностике новой коронавирусной инфекции COVID-19. Среди представленных работ все используют в качестве входных данных изображения. Использование стандартных решений библиотеки Keras в сочетании с трансферным обучением и тонкой настройкой гиперпараметров позволило достичь точности и специфичности работы моделей на уровне более чем 95 %, что позволяет говорить о возможности их применения в реальной клинической практике учреждений здравоохранения.

Исследования по разработке СППВР для применения в офтальмологии традиционно носят редкий характер. Среди представленных работ в равной степени входными данными являются изображения офтальмоскопии и клинических данных пациентов в табличном виде. Авторы исследований предпочли стандартные архитектуры собственным, разработанным специально для решения задач диагностики заболеваний глаза.

Возможности создания СППВР для прогнозирования исходов терапии на основе клинических данных пациентов в табличной форме были рассмотрены в двух работах. Общим для них является применение авторских

архитектур ИНС или ансамблей моделей машинного обучения.

Рассмотрим более подробно СППВР, предложенные Karim M. в исследованиях [7, 8] для использования в онкологии и ревматологии. Так, OncoNetExplainer [8] позиционируется как СППВР, предназначенная для определения зависимости генного профиля опухоли и исхода терапии. Большая размерность данных, связанных с гетерогенностью генного профиля и количеством биомаркеров делает невозможным использование традиционных методов машинного обучения для анализа данных, представленных в табличном виде. В качестве архитектуры ИНС были выбраны стандартные модели, обученные на наборе данных, состоящем из описания геномного профиля опухолей более чем 9000 онкологических больных по 33 видам рака. Используя при разработке системы методы объяснительного искусственного интеллекта GBP, Grad-CAM++, SHAP удалось получить возможность предоставления клиницистам визуального объяснения. Средняя точность рассмотренной системы составила 92,6 %. В свою очередь, DeepKneeExplainer [7] призван помочь ревматологам в диагностике остеопороза на основе рентгеновских снимков. Используя адаптированные под данную задачу алгоритмы предобработки изображения, ИНС происходит сегментация поступающего изображения. Для получения объяснений предсказанных изображений используются LRP Grad-CAM++. Заявленная точность решения – 91 %.

На основании сравнения характеристик можно сделать вывод о том, что наиболее часто для создания СППВР или подобных решений используются авторские архитектуры ИНС, что позволяет достичь лучшей точности по сравнению со стандартными аналогами. В качестве методов объяснения наиболее часто использовались Grad-CAM и его вариации (n=5), а также LIME (n=3) SHAP (n=3) в равных соотношениях.

V. Заключение

Применение методов XAI в построении СППВР на основе ИНС имеет значительные преимущества, по сравнению с стандартными СППВР, однако следует учитывать как особенности работы разных ИНС с различными методами XAI, так и необходимость построения удобного интерактивного интерфейса. Необходимо проводить больше исследований для отработки технологии с участием клиницистов и апробацией в реальной клинической практике.

ТАБЛИЦА I. Сравнение характеристик решений СППВР

Название / Автор	**Область применения**	**Метод XAI**	**Характеристика ИНС**		**Характеристика данных**		**Тип СППВР**
			Архитектура	**Результат**	**Тип данных**	**Набор данных**	
OncoNetExplainer [8]	Онкология	GBP GradCAM++ SHAP	VGG-16	AP 96.25%	Табличные	Авторский (9074 записи, 33 признака)	Незаниевые
DeepKneeExplainer [7]	Ревматология	GradCAM++ LRP	U-Net	91%	Изображения	MOST	
Kaji D. [5]	Прогнозирование исхода пациентов	Activation maximization	Авторская RNN	AUC 0.876	Табличные	MIMIC-III Clinical Dataset	
Zhang L. [16]		LIME SHAP	Ансамбль моделей	AUROC 0.813	Табличные	MIMIC-IV Database eICU-CRD Database ZG Database	
Kermany D. [9]	Офтальмология	Feature importance	Авторская CNN	Accuracy 93% Specify 94% Sensitivity 97%	Изображения	Авторский (207130 OCT-снимков, 5232 рентген-снимков)	
Tsao H. [13]		Features weights	Авторская CNN	Accuracy 0.83 Specify 0.72 Sensitivity 0.69 AUC 0.738	Табличные	Авторский (клинические записи 536 пациентов)	
Kamal M. [6]		LIME SP-LIME	Авторская SNN	Accuracy 96%	Изображения Табличные	Авторский (650 изображений и клинических записей)	
Yang Y. [15]	Лучевая диагностика	GradCAM	VGG-16 ResNet-50	Accuracy 95%	Изображения	Авторский (5840 рентген-снимков)	
Zou L. [17]		LIME SHAP GradCAM GradCAM++	Авторская, Xception, VGG-16	Accuracy 0.811 AUC 0.803	Изображения	Авторский	
Hu Q. [3]		CAM	VGG-16 ResNet-152 InceptionV3 EfficentNet	Accuracy 0.95	Изображения	Covid Chestxray Dataset	
Ieracitano C. [4]		Saliency maps	CovNNet	Accuracy 75.6% Specificity 75% Sensitivity 76%	Изображения	Авторский	

Список литературы

[1] Arrieta A.B. et al. Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI // Information fusion. 2020. V. 58. Pp. 82-115. DOI: 10.1016/j.inffus.2019.12.012

[2] Averkin A.N., Yarushev S.A. Review of research in the field of developing methods to extract rules from artificial neural networks // Journal of Computer and Systems Sciences International. 2021. V. 60. Pp. 966-980. DOI: 10.1134/S1064230721060046

[3] Hu Q. et al. Explainable artificial intelligence-based edge fuzzy images for COVID-19 detection and identification //Applied Soft Computing. 2022. V. 123. Pp. 108966. DOI: 10.1016/j.asoc.2022.108966

[4] Ieracitano C. et al. A fuzzy-enhanced deep learning approach for early detection of Covid-19 pneumonia from portable chest X-ray images //Neurocomputing. 2022. V. 481. Pp. 202-215. DOI: 10.1016/j.neucom.2022.01.055

[5] Kaji D. A. et al. An attention based deep learning model of clinical events in the intensive care unit // PloS one. 2019. V. 14. №. 2. Pp. e0211057. DOI: 10.1371/journal.pone.0211057

[6] Kamal M. S. et al. Explainable AI for glaucoma prediction analysis to understand risk factors in treatment planning // IEEE Transactions on Instrumentation and Measurement. 2022. V. 71. Pp. 1-9. DOI: 10.1109/TIM.2022.3171613

[7] Karim M.R. et al. DeepKneeExplainer: explainable knee osteoarthritis diagnosis from radiographs and magnetic resonance imaging // IEEE Access. 2021. V. 9. Pp. 39757-39780. DOI: 10.1109/ACCESS.2021.3062493

[8] Karim M.R. et al. OncoNetExplainer: explainable predictions of cancer types based on gene expression data // 2019 IEEE 19th International Conference on Bioinformatics and Bioengineering (BIBE). IEEE, 2019. P. 415-422. DOI: 10.1109/BIBE.2019.00081

[9] Kermany D.S. et al. Identifying medical diagnoses and treatable diseases by image-based deep learning // Cell. 2018. V. 172. №. 5. Pp. 1122-1131. e9. DOI: 10.1016/j.cell.2018.02.010

[10] Saraswat D. et al. Explainable AI for healthcare 5.0: opportunities and challenges // IEEE Access. 2022. DOI: 10.1109/ACCESS.2022.3197671.

[11] Sheu R.K., Pardeshi M.S. A Survey on Medical Explainable AI (XAI): Recent Progress, Explainability Approach, Human Interaction and Scoring System // Sensors. 2022. V. 22. №. 20. Pp. 8068.

[12] Sutton R.T. et al. An overview of clinical decision support systems: benefits, risks, and strategies for success // NPJ digital medicine. 2020. V. 3. №. 1. Pp. 17.

[13] Tsao H.Y., Chan P.Y., Su E. C.Y. Predicting diabetic retinopathy and identifying interpretable biomedical features using machine learning algorithms //BMC bioinformatics. 2018. V. 19. Pp. 111-121. DOI: 10.1186/s12859-018-2277-0

[14] Xu Q. et al. Interpretability of Clinical Decision Support Systems Based on Artificial Intelligence from Technological and Medical Perspective: A Systematic Review // Journal of Healthcare Engineering. 2023. V. 2023. DOI: 10.1155/2023/9919269

[15] Yang Y., Mei G., Piccialli F. A Deep Learning Approach Considering Image Background for Pneumonia Identification Using Explainable AI (XAI) // IEEE/ACM Transactions on Computational Biology and Bioinformatics. 2022. DOI: 10.1109/TCBB.2022.3190265

[16] Zhang L. et al. Developing an ensemble machine learning model for early prediction of sepsis-associated acute kidney injury // Iscience. 2022. V. 25. №. 9. Pp. 104932. DOI: 10.1016/j.isci.2022.104932

[17] Zou L. et al. Ensemble image explainable AI (XAI) algorithm for severe community-acquired pneumonia and COVID-19 respiratory infections // IEEE Transactions on Artificial Intelligence. 2022. V. 4. №. 2. Pp. 242-254. DOI: 10.1109/TAI.2022.3153754

Gradient-based методы объяснительного искусственного интеллекта для классификации заболеваний глаза

Е. Н. Волков[1], А. Н. Аверкин[2]
[1] *Государственный университет «Дубна»*
[2] *ФИЦ «Информатика и управление» РАН*
envolkoff1998@yandex.ru

Аннотация. **В последние несколько лет тема объяснимости стала одним из трендов в сфере искусственного интеллекта. Появляется всё больше методов объяснения результатов работы искусственных нейронных сетей – методов объяснительного искусственного интеллекта, которые с успехом находят своё применения для решения множества различных задач. Методы, основанные на вычислении градиента (gradient-based), становятся популярными применительно к задачам работы с изображениями. В нашем исследовании представлено теоретическое описание и практическая реализация нескольких методов объяснительного искусственного интеллекта, относящихся к приведённым классам на примере объяснения результатов работы искусственной нейронной сети для задачи классификации изображений офтальмологических заболеваний.**

Ключевые слова: искусственный интеллект, объяснительный искусственный интеллект, объяснимый искусственный интеллект, гибридный искусственный интеллект, катаракта, глаукома, диабетическая ретинопатия, персонализированная медицина

I. Введение

Несмотря на достижения современной медицины такие офтальмологические заболевания как диабетическая ретинопатия, катаракта и глаукома имеют на сегодняшний день наибольшее распространение среди населения Земли. Указанные заболевания при несвоевременном выявлении способны привести к частичной или полной потере зрения. Например, по данным исследования [6], на 2022 год около 4 % населения планеты страдают от глаукомы. Своевременная диагностика, во многом, зависит от квалификации врача офтальмолога. Использование решений, основанных на технологии искусственного интеллекта, может существенно улучшить ситуацию. Однако, невозможность объяснения результатов работы искусственных нейросетей и поступательное усложнение их архитектур ставит уменьшает доверие к технологии. Выходом из ситуации становится создание решений, содержащих методы объяснения результатов работы искусственных нейронных сетей – методы объяснительного искусственного интеллекта (от англ. eXplainable Artificial Intelligence (XAI)).

Объяснительный искусственный интеллект как совокупность методов, применяемых к модели машинного обучения, позволяет с помощью графического интерфейса получить представление о том, почему исследуемая модель получила определённый результат, но не позволяет проследить алгоритм его получения. XAI прошёл в своём развитии несколько этапов, представленных в работе [1], и сейчас переживает бум благодаря программе DARPA.

Использование методов XAI в медицинских системах позволяет говорить о постепенном переходе к концепции Здравоохранение 5.0, основными чертами которой является объяснимость, использование гибридного искусственного интеллекта, что позволит создать персонализированных подход для каждого пациента, улучшить качество постановки диагноза. [7]

II. Методология

A. Gradient-based методы XAI

Grad-CAM (Gradient-weighted Class Activation Mapping) использует градиентно-взвешенное отображение карты активации классов на целевом слое для отображения вывода в виде тепловой карты. Был предложен Selvaraju R. в 2017 году [8].

Vanilla Gradient метод XAI, основанный на идее использовании карт заметности и вычислении градиента функции потерь целевого класса. Был предложен Simonyan K. в 2013 году [9].

Guided IG (Guided Integrated Gradients) был предложен А. Капишниковым в 2021 году [3]. Отличительной чертой Guided IG является применение адаптации пути атрибуции интегрированного градиента, позволяющее снизить количество шума и тем самым создать более точное объяснение результата.

Blur IG (Blur Integrated Gradients) был предложен Xu S. в 2020 году [12]. Метод получил популярность благодаря устранению необходимости использования baseline в качестве параметра, вместо которого используется размытие, что помогает снизить влияние на результат.

XRAI (eXplainable Representations through AI) – является апостериорным методом объяснения, был предложен А. Капишниковым в 2019 году [4]. Суть метода состоит в объединении применения встроенных градиентных методов с сегментацией входного изображения и ранжированием полученных сегментов по вкладу, внесённому в предсказание. Алгоритм работы метода представлен на рис. 1.

Algorithm 1 XRAI

Given image $\boldsymbol{I}$, model f and attribution method g
Over-segment $\boldsymbol{I}$ to segments $s \in S$
Get attribution map $A = g(f, I)$
Let saliency mask $M = \mathbf{0}$, trajectory $T = []$
while $S \neq \emptyset \ and \ area(M) < area(I)$ **do**
  for $s \in S$ **do**
    Compute gain[2]: $g_s = \sum_{i \in s \setminus M} \frac{A_i}{area(s \setminus M)}$
  end for
  $\hat{s} = \arg\max_s g_s$
  $S = S \setminus \hat{s}$
  $M = M \cup \hat{s}$
  Add M to list T
end while
return T

Рис. 1. Алгоритм работы метода XRAI

B. *Искусственная нейронная сеть*

Для обучения и дальнейшей интерпретации нами была выбрана нейросеть архитектуры VGG-16 (рис. 2). Архитектура была представлена Simonyan K. и Zisserman A. в 2014 году. Нейросеть состоит из 21 слоя (13 свёрточных слоёв, 5 MaxPooling-слоёв, 3 Dense-слоя). При тестировании на наборе изображений ImageNet показала наибольший результат в 92,7 %. [10]

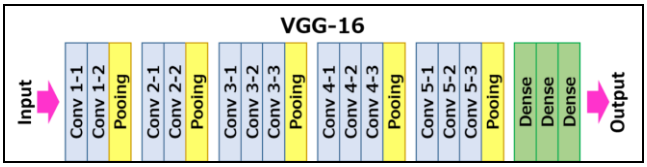

Рис. 2. Архитектура VGG-16

C. *Наборы данных*

При работе с наборами данных медицинской тематики особенно важно быть уверенным в корректности разметки, проведённой профессионалами. Однако, как и для всех наборов изображений медицинской тематики, такое требование сказывается на их доступности. Так, например, Khan S.M. в глобальном обзоре доступных наборов офтальмологических изображений [5] приводит лишь 10 датасетов, содержащих размеченные изображения глаукомы и диабетической ретинопатии. Количество изображений в подобных наборах данных также оставляет желать лучшего, что часто приводит к несбалансированности классов. Используемые в данной работе наборы данных, количество изображений и соотношений классов в них приведено в табл. I.

ТАБЛИЦА I. НАБОРЫ ДАННЫХ

Заболевание / набор данных	**Наименование классов**	**Соотношение классов изображений**	**Всего изображений**
Диабетическая ретинопатия [2]	Normal	4250 / 69%	6174
	DR_Mild	795 / 13%	
	Prolif_DR	674 / 11%	
	Severe_DR	455 / 7%	
Глаукома [11]	Normal	551 / 38%	1450
	Glaucoma	899 / 62%	
Катаракта	Normal	319 / 37%	872
	Cataract	553 / 63%	

III. РЕЗУЛЬТАТЫ И ОБСУЖДЕНИЕ

A. *Обучение нейросети*

В нашей работе мы использовали предварительно обученную на наборе данных ImageNet нейросеть VGG-16 из библиотеки моделей Keras, адаптировав её для целей исследования, проведя трансферное обучение (transfer learning) на представленных в табл. I наборах данных. Для повышения точности классификации были применены методы тонкой настройки дообученной сети (fine-tuning). Результаты, показанные сетью на тренировочной и тестовой выборках, приведены в табл. II.

ТАБЛИЦА II. РЕЗУЛЬТАТЫ ОБУЧЕНИЯ

Выборка	**Датасет**	**Класс**	**Accuracy**	**Loss**
Train	Диабетическая ретинопатия	Normal	0.96	0.03
		DR_Mild	0.91	0.1
		Prolif_DR	0.95	0.3
		Severe_DR	0.9	0.4
	Глаукома	Normal	0.98	0.1
		Glaucoma	0.94	0.3
	Катаракта	Normal	0.9	0.3
		Cataract	0.87	0.4
Test	Диабетическая ретинопатия	Normal	0.94	0.2
		DR_Mild	0.91	0.2
		Prolif_DR	0.87	0.3
		Severe_DR	0.86	0.2
	Глаукома	Normal	0.96	0.1
		Glaucoma	0.88	0.6
	Катаракта	Normal	0.82	0.4
		Cataract	0.8	0.6

B. *Имплементация методов XAI и получение объяснений*

Процесс имплементации для gradient-based методов отличается от такового для других, поскольку, методы, использующие в своей основе вычисление градиента, относятся к группе specific-методов XAI и используют вычислительный граф для получения объяснений. В случае с градиентными методами необходимо установить целевой слой, из которого будет происходить извлечение признаков. Для архитектуры VGG-16 таким слоем служит финальный свёрточный слой из 5 блока (block5_conv3), имеющий размерность 7×7×512. Результаты объяснений, полученных с помощью Grad-CAM, Vanilla Gradient, Guided IG, Blur IG, XRAI представлены на рис. 3.

При получении объяснений с помощью XRAI возможно изменять порог уровня вклада в результат предсказания за счёт чего возможно более точно сегментировать зоны интереса (рис. 4, 5). Возможности изменения порога значений повышают возможности данного метода.

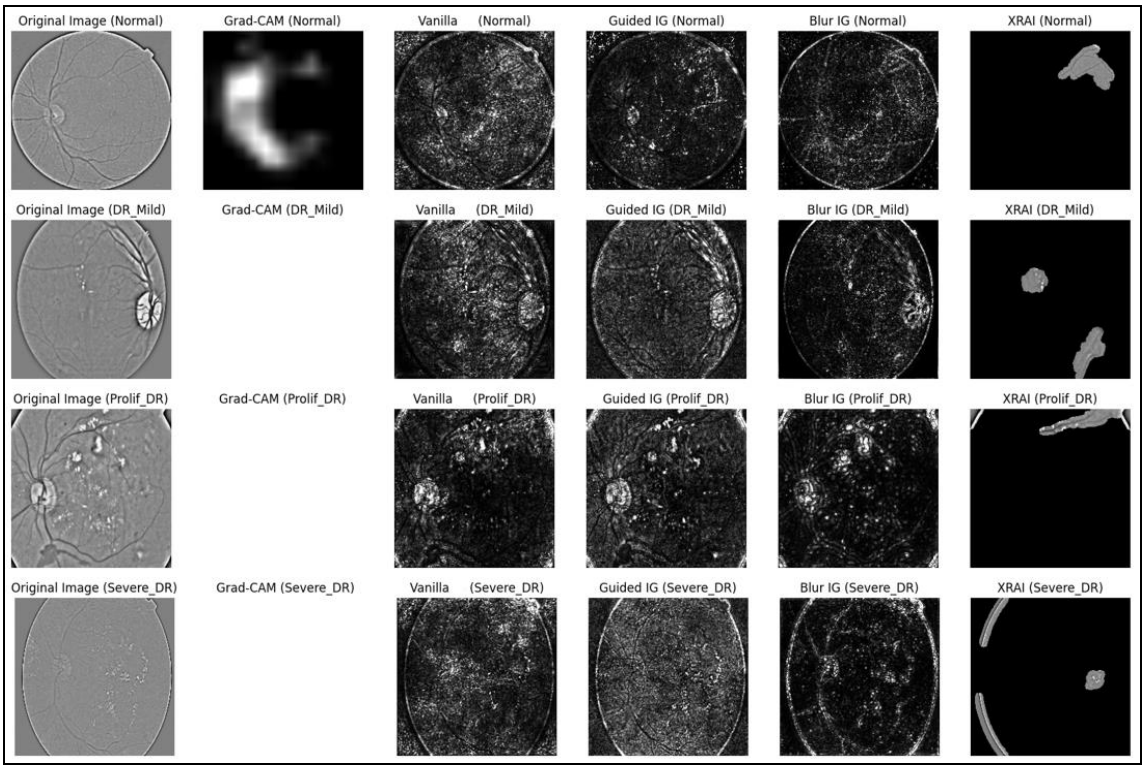

Рис. 3. Сравнение результатов объяснения, полученных с помощью Grad-CAM, Vanilla Gradient, Guided IG, Blur IG, XRAI в задаче классификации изображений поражения глаза диабетической ретинопатии разной степени тяжести

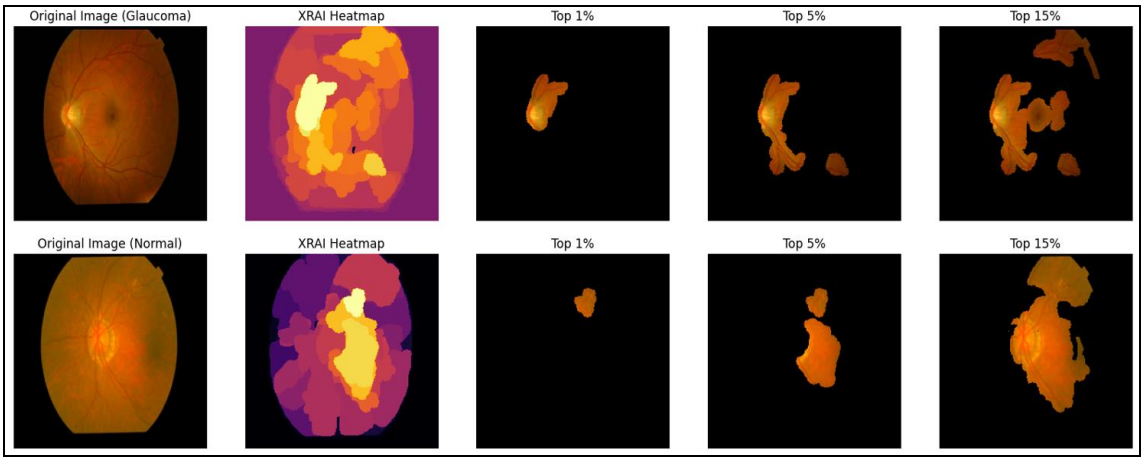

Рис. 4. Применение XRAI к задаче бинарной классификации поражения глаза глаукомой

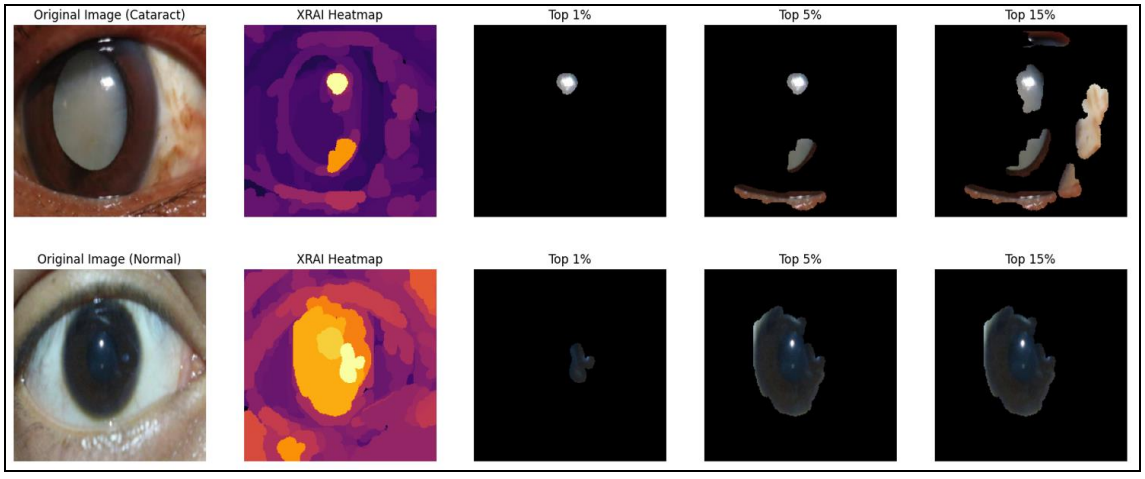

Рис. 5. Применение XRAI к задаче бинарной классификации поражения хрусталика глаза катарактой

IV. Заключение

В работе были рассмотрены некоторые gradient-based методы объяснительного искусственного интеллекта, (Grad-CAM, Vanilla Gradient, Guided IG, Blur IG, XRAI). Приведено теоретическое описание работы и представлены возможности практической реализации для задач бинарной и мультиклассовой классификации. В качестве объекта интерпретации была выбрана искусственная нейросеть архитектуры VGG-16, дообученная для задач классификации офтальмологических изображений (диабетическая ретинопатия, катаракта, глаукома).

Результаты практической реализации методов объяснения для задач офтальмологии показывают возможности использования данных методов при построении медицинских систем поддержки принятия решений (МСППР). Применение данных методов способно вывести МСППР на совершенно новый уровень, что соответствует заявленным принципам концепции Здравоохранение 5.0. Однако, стоит отметить, что низкая доступность наборов данных для обучения нейросетей сказывается как на трудоёмкости процессов создания подобных решений, так и на их точности.

Список литературы

[1] Averkin A.N., Yarushev S.A. Review of Research in the Field of Developing Methods to Extract Rules From Artificial Neural Networks // Journal of Computer and Systems Sciences International. 2021. Vol. 60, No. 6. P. 966-980. DOI 10.1134/S1064230721060046.

[2] Diabetic retinopathy dataset // Roboflow URL: https://universe.roboflow.com/srm-ahou5/diabetic_retinopathy-tmdms (дата обращения: 21.02.2023).

[3] Kapishnikov A. et al. Guided integrated gradients: An adaptive path method for removing noise // Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. 2021. Pp. 5050-5058.

[4] Kapishnikov A. et al. Xrai: Better attributions through regions // Proceedings of the IEEE/CVF International Conference on Computer Vision. 2019. Pp. 4948-4957.

[5] Khan S.M. et al. A global review of publicly available datasets for ophthalmological imaging: barriers to access, usability, and generalisability // The Lancet Digital Health. 2021. V. 3. №. 1. Pp. e51-e66. DOI: 10.1016/S2589-7500(20)30240-5

[6] Mamtora S., Leadbetter D., Atan D. Identification and management of glaucoma // Prescriber. 2022. V. 33. №. 5. Pp. 17-22. DOI: 10.1002/psb.1985

[7] Saraswat D. et al. Explainable AI for healthcare 5.0: opportunities and challenges // IEEE Access. 2022. DOI: 10.1109/ACCESS.2022.3197671

[8] Selvaraju R.R. et al. Grad-cam: Visual explanations from deep networks via gradient-based localization // Proceedings of the IEEE international conference on computer vision. 2017. Pp. 618-626.

[9] Simonyan K., Vedaldi A., Zisserman A. Deep inside convolutional networks: Visualising image classification models and saliency maps //arXiv preprint arXiv:1312.6034. 2013.

[10] Simonyan K., Zisserman A. Very deep convolutional networks for large-scale image recognition //arXiv preprint arXiv:1409.1556. 2014.

[11] Wheyming Song, March 31, 2020, "1450 fundus images with 899 glaucoma data and 551 normal data.", IEEE Dataport, DOI: 10.21227/4bcp-2z21

[12] Xu S., Venugopalan S., Sundararajan M. Attribution in scale and space // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2020. Pp. 9680-9689.

Алгоритм скользящего управления в сочетании с нейронной сетью для системы электроприводов экзоскелета

Динь Данг Чыонг[1], Нгуен Динь Хань[2], Ха Ван Муон[3]
[1,2]*Вьетнамский государственный технический университет им. Лэ Куй Дона*
[3]*Вьетнамский телекоммуникационный университет*
[1]dinhdangtruong@gmail.com, [2]dinhkhanhmta@gmail.com, [3]muon.ha@mail.ru

***Аннотация*. В статье представляется робастный алгоритм скользящего управления с нейронной сетью для устранения неопределенных параметров и внешних возмущений динамической модели нижних конечностей экзоскелета. Скользящее управление используется для достижения быстрой сходимости за конечное время и подавления возмущений. В систему управления интегрируется нейросетевой оценщик для оценки параметров и модели объекта управления. Робастная система управления способна реагировать на изменение внешних возмущений и параметров динамической модели экзоскелета. Устойчивость предложенного регулятора и эффективность слежения системы управления доказаны теоремой Ляпунова об устойчивости.**

Ключевые слова: экзоскелет, скользящее управление, нейронная сеть, нелинейная система, электропривод, регулятор

I. Введение

Для управления системой экзоскелета нижних конечностей предназначены различные контроллеры, такие как регулятор скользящего режима [1], адаптивное управление [2], управление по Ляпунову [3] и др. Известно, что регулятор скользящего режима лучше справляется с подавлением неопределенности параметров, лучшими свойствами точности, робастности и простоты настройки и реализации. Были предприняты различные попытки реализации других вариантов регулятора скользящего режима на экзоскелете [4]. В статьях [5–10] рассмотрены некоторые вариации скользящего режима управления. Однако есть трудности с возникновением нестабильности ошибки состояния, низкой прочностью и переоценкой границы возмущения, которая необходима для устранения возмущения. В данной работе представлен алгоритм управления скользящим режимом в сочетании с нейронной сетью, позволяющий подавлять изменения параметров динамической модели экзоскелета, внешних возмущений, обеспечивающий хорошую сходимость и обладающий прочность. Динамическая математическая модель нижней конечности экзоскелета, включающая 5 суставов с расчетом нелинейных электроприводов и внешнего возмущения, строится для анализа и демонстрации эффективности алгоритма управления.

II. Динамическая модель нижних конечностей экзоскелета с электроприводами с внешним возмущением

Рассмотрим моделирование динамики экзоскелета-человека, представленного в виде пятизвенной двуногой системы, имеющей корпус в сагиттальной плоскости на основе принципов Лагранжа [11]. Математическая модель динамики с пятизвенной системой нижних конечностей экзоскелета-человека с учетом нелинейных элементов электроприводов представлена в виде (1).

$$\mathbf{M}(q)\ddot{q} + \mathbf{D}(q,\dot{q})\dot{q} + \mathbf{G}(q) + \mathbf{F}(q,\dot{q}) + \mathbf{U}_h = \mathbf{U} \qquad (1)$$

где $q \in \mathbb{R}^n$ — обобщенная координата позиции звеньев;

$$\mathbf{M}(q) = \begin{bmatrix} m_{11}+m_1 & m_{12} & m_{13} & m_{14} & m_{15} \\ m_{21} & m_{22}+m_2 & m_{23} & m_{24} & m_{25} \\ m_{31} & m_{32} & m_{33}+m_3 & m_{34} & m_{35} \\ m_{41} & m_{42} & m_{43} & m_{44}+m_4 & m_{45} \\ m_{51} & m_{52} & m_{53} & m_{54} & m_{55}+m_5 \end{bmatrix}$$

где $\mathbf{m} = \mathbf{diag}\{m_1, m_2, m_3, m_4, m_5\} = \mathbf{diag}\{r_i^2 J_{mi}\}$; m_{ij} – элементы матрицы инерции $\mathbf{M}(q)$; r_i – передаточное отношение редуктора суставов; J_{mi} – момент инерции двигателей.

$$\mathbf{D}(q,\dot{q}) = \begin{bmatrix} d_{11}+d_1 & d_{12} & d_{13} & d_{14} & d_{15} \\ d_{21} & d_{22}+d_2 & d_{23} & d_{24} & d_{25} \\ d_{31} & d_{32} & d_{33}+d_3 & d_{34} & d_{35} \\ d_{41} & d_{42} & d_{43} & d_{44}+d_4 & d_{45} \\ d_{51} & d_{52} & d_{53} & d_{54} & d_{55}+d_5 \end{bmatrix}$$

где $\mathbf{d} = \mathbf{diag}\{d_1, d_2, d_3, d_4, d_5\} = \mathbf{diag}\left\{r_i^2 b_{mi} + \dfrac{r_i^2 k_{vi} k_{ti}}{R_i}\right\}$; d – элементы матрицы $\mathbf{D}(q,\dot{q})$, содержащей центробежные силы и силы Кориолиса; b_{mi} – коэффициенты вязкого трения двигателей; k_v – константа электродвижущей силы; k_t – константа момента двигателя; R – сопротивление фазной обмотки двигателя; $\mathbf{G}(q) = [g_1, g_2, g_3, g_4, g_5]^T$ – вектор, содержащий моменты силы тяжести;

$\mathbf{F}(q,\dot{q}) = [f_1,\ f_2,\ f_3,\ f_4,\ f_5]^T$ – функция момента упругости и трения представлена Кулоновским трением, вязким трением; k_s – эквивалентная жесткость упругой связи привода.

$$f_i = b_e\dot{q}_i + \gamma sign(\dot{q}_i) + r_i k_s\left(r_i - 1\right)q_i + r_i\alpha sign(r_i\dot{q}_i)$$

$\mathbf{U}_h$ – вектор момента внешних возмущений; b_e – коэффициенты вязкого трения суставов экзоскелета.

$$\mathbf{U} = \left[\frac{r_1 k_{t1}}{R_1}u_1,\ \frac{r_2 k_{t2}}{R_2}u_2,\ \frac{r_3 k_{t3}}{R_3}u_3,\ \frac{r_4 k_{t4}}{R_4}u_4,\ \frac{r_5 k_{t5}}{R_5}u_5\right]^T$$ –

вектор управляющего момента.

III. Алгоритм скользящего управления с нейронной сетью для системы электроприводов экзоскелета

В этом разделе представляется разработка алгоритма скользящего управления в сочетании с нейронной сетью (СУ-НС) для следящего управления углового положения звеньев нижних конечностей экзоскелета. Для быстрого увеличения влияния необходимо выбирать поверхность скольжения с большим уклоном и медленным изменением с малым отклонением. Алгоритма скользящего управления обеспечивает большой уклон поверхности скольжения, управление диапазоном отклонений за конечное время и позволяет уменьшать время переходного процесса.

Алгоритм скользящего управления обеспечивает адаптацию системы независимо от влияния на нее возмущений и изменений параметров. Матрица $\mathbf{M}$ имеет положительный определитель, поэтому уравнение (1) преобразуется в виде (2).

$$\ddot{\mathbf{q}} = \mathbf{M}^{-1}(q)\left\{\mathbf{U} - \mathbf{D}(q,\dot{q}) - \mathbf{G}(q) - \mathbf{F}(q,\dot{q}) - \mathbf{U}_h\right\} \qquad (2)$$

Выбор поверхности скольжения переключения имеет следующий вид:

$$\mathbf{s} = \dot{\mathbf{e}} + \boldsymbol{\beta}\mathbf{e} \qquad (3)$$

При действии закона управления траектория состояния $\mathbf{q}$ будет сдвигаться в положение на поверхности и навсегда останется на ней. Для этой реализация рассматривается уравнение кинематической устойчивости замкнуто-открытой поверхности скольжения.

$$\dot{\mathbf{s}} + \boldsymbol{\beta}\mathbf{s} + \mathbf{K}tg(\boldsymbol{\gamma}\mathbf{s}) = 0 \qquad (4)$$

где $\mathbf{K} = diag(k_1, k_2, k_3, k_4, k_5)$ – положительно определенная матрица, $\dot{\mathbf{s}} + \boldsymbol{\beta}\mathbf{s}$, $\mathbf{K}tg(\boldsymbol{\gamma}\mathbf{s})$ – матрицы, обеспечивающие экспоненциальную устойчивость и поддержание робастной устойчивости поверхности скольжения соответственно.

Подставляя уравнение (2) и (3) в уравнение (4) получаем алгоритм скользящего управления в виде:

$$\begin{aligned}\mathbf{U}(q,\dot{q}) = -\mathbf{M}(q)\left\{2\boldsymbol{\beta}\dot{\mathbf{q}} + \boldsymbol{\beta}^{\mathbf{T}}\boldsymbol{\beta}\left(\mathbf{q} - \mathbf{q}_d\right) + \mathbf{K}tg\left(\boldsymbol{\gamma}\mathbf{s}\right)\right\} + \\ + \mathbf{D}(q,\dot{q}) + \mathbf{G}(q) + \mathbf{F}(q,\dot{q}) + \mathbf{U}_h\end{aligned} \qquad (5)$$

Регулятор (5) эффективно используется даже в тех случаях, когда параметры системы неопределенны, но при этом все равно необходима информация от объекта управления.

Робастно-адаптивный регулятор не требует знания большинства компонентов предлагаемого объекта управления. Оценщик нейронной сети разработается и интегрируется в контур управления для его оценки, включая $\mathbf{M}(q)$, $\mathbf{D}(q,\dot{q})$, $\mathbf{G}(q)$. Алгоритм управления СУ-НС переписывается следующим образом:

$$\mathbf{U}(q,\dot{q}) = \mathbf{f}(q,\dot{q}) - \mathbf{M}(q)\begin{Bmatrix}2\boldsymbol{\beta}\dot{\mathbf{q}} + \boldsymbol{\beta}^{\mathbf{T}}\boldsymbol{\beta}\left(\mathbf{q} - \mathbf{q}_d\right) \\ +\mathbf{K}tg\left(\boldsymbol{\gamma}\mathbf{s}\right)\end{Bmatrix} \qquad (6)$$

где

$$\mathbf{f}(q,\dot{q}) = \mathbf{D}(q,\dot{q}) + \mathbf{G}(q) + \mathbf{F}(q,\dot{q}) + \mathbf{U}_h = \mathbf{U}_n \qquad (7)$$

Используем нейронную сеть для оценки скрытой функции (7) регулятора (6).

$\tilde{\mathbf{f}}(q,\dot{q}) = \hat{\mathbf{f}}(q,\dot{q}) - \mathbf{f}(q,\dot{q}) = \hat{\mathbf{W}}^{\mathrm{T}}\mathbf{h}(z)$ - нелинейная аппроксимация функции $\mathbf{f}(q,\dot{q})$. Алгоритм управления (6) записывается в форме адаптации следующим образом:

$$\mathbf{U}(q,\dot{q}) = \hat{\mathbf{f}}(q,\dot{q}) - \mathbf{M}(q)\begin{Bmatrix}2\boldsymbol{\beta}\dot{\mathbf{q}} + \boldsymbol{\beta}^{\mathbf{T}}\boldsymbol{\beta}\left(\mathbf{q} - \mathbf{q}_d\right) \\ +\mathbf{K}tg\left(\boldsymbol{\gamma}\mathbf{s}\right)\end{Bmatrix} \qquad (8)$$

где $\hat{\mathbf{f}}(q,\dot{q}) = \hat{\mathbf{D}}(q,\dot{q}) + \hat{\mathbf{G}}(q) + \hat{\mathbf{F}}(q,\dot{q}) + \hat{\mathbf{U}}_h$ – вектор нелинейной функции, который можно оценить.

Сигнал приближения нейронной сети $\mathbf{f}(z)$ определяется:

$$\mathbf{f}(z) = \mathbf{W}^T\mathbf{h}(z) + \boldsymbol{\varepsilon} \qquad (9)$$

где $\mathbf{W}$ – идеальная матрица веса; $\mathbf{h}(z)$ – функция активации; $\boldsymbol{\varepsilon}$ – модель ошибки нейронной сети.

Сигнал приближения нейронной сети выражается следующим образом:

$$\hat{\mathbf{f}}(z) = \hat{\mathbf{W}}^T\mathbf{h}(z) \qquad (10)$$

Как видно из уравнения (10), ошибка модели ε мала, поэтому ей можно пренебречь.

Рассмотрим функцию Ляпунов в виде:

$$V = \frac{1}{2}\mathbf{s}^T\mathbf{M}(q) + \frac{1}{2}trace(\tilde{\mathbf{W}}^T\boldsymbol{\Gamma}^{-1}\tilde{\mathbf{W}}) \qquad (11)$$

где $\tilde{\mathbf{W}} = \hat{\mathbf{W}} - \mathbf{W}$ – ошибка матрицы веса; $\hat{\mathbf{W}}$ – приближение матрицы веса.

Производная функции Ляпунова будет:

$$\dot{V} = \mathbf{s}^T\mathbf{M}(q)\dot{\mathbf{s}} + trace(\tilde{\mathbf{W}}^T\boldsymbol{\Gamma}^{-1}\dot{\hat{\mathbf{W}}}) \qquad (12)$$

где $\dot{\hat{\mathbf{W}}} = -\boldsymbol{\Gamma}\mathbf{h}(z)\mathbf{s}^T$ – приближение матрицы веса, $\boldsymbol{\Gamma} = diag(\Gamma_1, \Gamma_2, ..., \Gamma_m)$ – определенная диагональная матрица.

Подставляя уравнение (2) в уравнение (4) получаем:

$$\dot{s} = \mathbf{M}^{-1}(q)\{\mathbf{U}(q,\dot{q}) - \mathbf{f}(q,\dot{q})\} + \boldsymbol{\beta}\dot{\mathbf{q}} \qquad (13)$$

Подставляя уравнение (8) в уравнение (12) имеем:

$$\dot{\mathbf{s}} + \boldsymbol{\beta}\mathbf{s} = \mathbf{M}^{-1}(q)\tilde{\mathbf{f}}(q,\dot{q}) - \mathbf{K}\,\mathrm{sgn}(\boldsymbol{\gamma}\mathbf{s}) \qquad (14)$$

где $\tilde{\mathbf{f}}(q,\dot{q}) = \hat{\mathbf{f}}(q,\dot{q}) - \mathbf{f}(q,\dot{q}) = \hat{\mathbf{W}}^{\mathrm{T}}\mathbf{h}(z)$ – ошибка оценки нелинейных элементов $\mathbf{f}(q,\dot{q})$.

Подставляя уравнение (13) в уравнение (1) получаем:

$$\dot{V} = \frac{1}{2}\mathbf{s}^T\mathbf{M}(q)\mathbf{s} + \frac{1}{2}trace(\tilde{\mathbf{W}}^T\boldsymbol{\Gamma}^{-1}\dot{\tilde{\mathbf{W}}})$$

$$\dot{V} = -\mathbf{s}^T\mathbf{M}(q)\boldsymbol{\beta}\mathbf{s} - \mathbf{s}^T\mathbf{M}(q)\mathbf{K}\,\mathrm{sgn}(\boldsymbol{\gamma}\mathbf{s}) + \mathbf{s}^{\mathrm{T}}\tilde{\mathbf{f}}(q,\dot{q}) + trace\left(\tilde{\mathbf{W}}^T\boldsymbol{\Gamma}^{-1}\dot{\tilde{\mathbf{W}}}\right)$$

$$\dot{V} = -\mathbf{s}^T\mathbf{M}(q)\boldsymbol{\beta}\mathbf{s} - \mathbf{s}^T\mathbf{M}(q)\mathbf{K}\,\mathrm{sgn}(\boldsymbol{\gamma}\mathbf{s}) + \mathbf{s}^T\tilde{\mathbf{W}}^T(q,\dot{q}) + trace\left(\tilde{\mathbf{W}}^T\boldsymbol{\Gamma}^{-1}\dot{\tilde{\mathbf{W}}}\right)$$

$$\dot{V} = -\mathbf{s}^T\mathbf{M}(q)\boldsymbol{\beta}\mathbf{s} - \mathbf{s}^T\mathbf{M}(q)\mathbf{K}\,\mathrm{sgn}(\boldsymbol{\gamma}\mathbf{s}) + trace\left\{\tilde{\mathbf{W}}^T\left[\boldsymbol{\Gamma}^{-1}\dot{\tilde{\mathbf{W}}} + \mathbf{s}^T\mathbf{h}(z)\right]\right\} \qquad (15)$$

Подставляя уравнение $\dot{\tilde{\mathbf{W}}} = -\boldsymbol{\Gamma}\mathbf{h}(z)\mathbf{s}^T$ в уравнение (12) имеем:

$$\dot{V} = -\mathbf{s}^T\mathbf{M}(q)\boldsymbol{\beta}\dot{\mathbf{s}} - \mathbf{s}^T\mathbf{M}(q)\mathbf{K}sgn(\boldsymbol{\gamma}\mathbf{s}) \qquad (16)$$

где $\mathbf{M}(q)$, $\boldsymbol{\beta}$, $\mathbf{K}$ – положительно-определенные матрицы, поэтому $\dot{V} \le 0$ или $V(t) \le V(0)$, $\forall t \ge 0$. Это показывает, что $\mathbf{s}$, $\tilde{\mathbf{W}}$ заблокированы. И так, поверхность скольжения асимптотически устойчива $\lim_{x\to\infty} \mathbf{s} = 0$.

IV. Моделирование системы управления

Моделирование алгоритма управления СУ-НС для системы электроприводов экзоскелета реализовано в среде Matlab/Simulink с внешним возмущением $\mathbf{U}_h = 10randn(1,1)$ (Н.м). Желанные траектории задаются следующим образом:

$q_{d1,5} = \sin(0.5t) + \sin(0.75t) + \cos(t) - 1$; $q_{d2,4} = 0.5\sin(t)$;

$q_{d3} = 0.25\sin(0.5t)$;

с изменением случайной массы (mL), описывающей тип белого шума: мощность 0.1, дискретное время 0.01с;

$\boldsymbol{\beta} = \mathbf{diag}(28,28,28,28,28)$;

$\mathbf{K} = \mathbf{diag}(796,796,796,796,796)$; $\boldsymbol{\gamma} = 0.65$.

Результаты моделирования показаны на рис. 1–7.

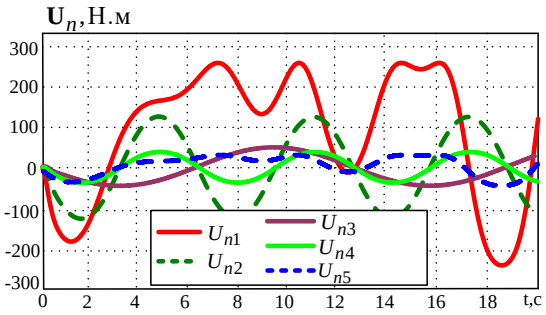

Рис. 1. Выводы нейронной сети

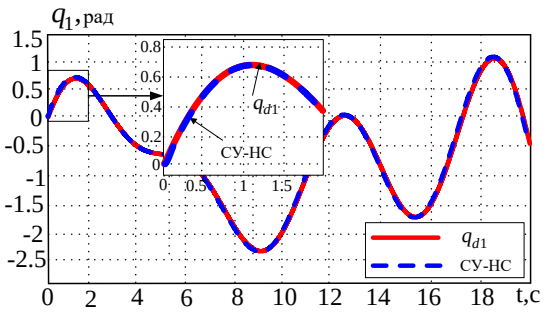

Рис. 2. Траектория движения коленного сустава q_1 (рад)

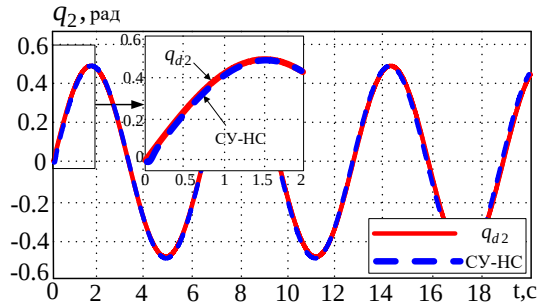

Рис. 3. Траектория движения тазобедренного сустава q_2 (рад)

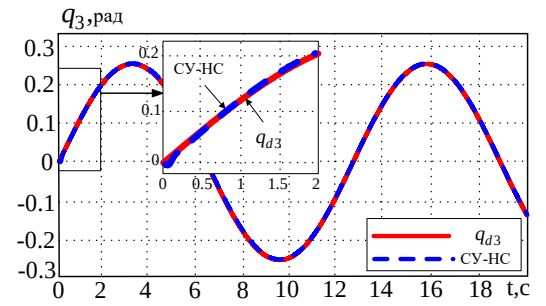

Рис. 4. Траектория движения сустава корпуса q_3 (рад)

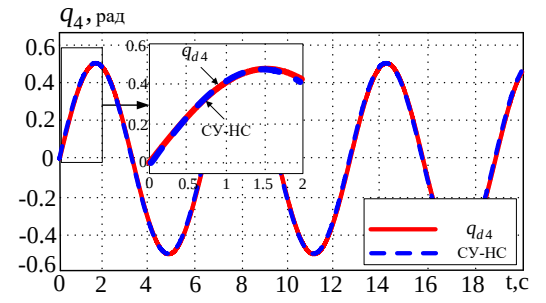

Рис. 5. Траектория движения тазобедренного сустава q_4 (рад)

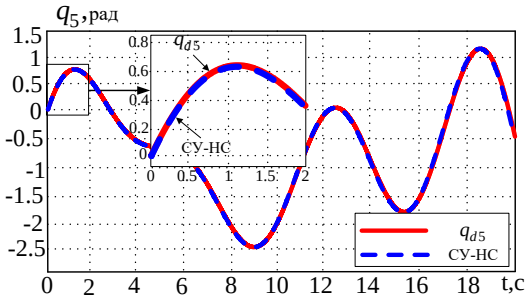

Рис. 6. Траектория движения коленного сустава q_5 (рад)

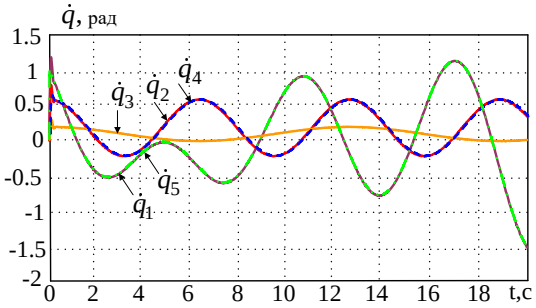

Рис. 7. Скорость траектория движения суставов (рад)

V. Заключение

В этой статье предлагается алгоритм управления скольжением второго порядка с нейронной сетью для системы электропривода экзоскелета с неопределенной структурой динамической модели. Алгоритм управления обеспечивает движение отслеживания высокой точности траектория суставных углов нижних конечностей экзоскелета, устойчивости, высокую робастность. Эффективность предложенного алгоритма управления доказана на основе теории устойчивого управления по Ляпунову и результатов моделирования в среде Matlab/Simulink.

Список литературы

[1] Y. Tu et al., “An adaptive sliding mode variable admittance control method for lower limb rehabilitation exoskeleton robot,” // Appl. Sci., vol. 10, no. 7, 2020, doi: 10.3390/app 10072536.

[2] F. Qin, H. Zhao, S. Zhen, and Y. Zhang, “Adaptive robust control for lower limb rehabilitation robot with uncertainty based on Udwadia–Kalaba approach,” // Adv. Robot., vol. 34, no. 15, pp. 1012–1022, 2020, doi: 10.1080/01691864.2020.1774414.

[3] D. Shi, W. Zhang, W. Zhang, L. Ju, and X. Ding, “Human-centred adaptive control of lower limb rehabilitation robot based on human–robot interaction dynamic model,” // Mech. Mach. Theory, vol. 162, p. 104340, 2021, doi: 10.1016/j.mechmachtheory. 2021.104340.

[4] J. Zhou, S. Yang, and Q. Xue, “Lower limb rehabilitation exoskeleton robot: A review,” // Adv. Mech. Eng., vol. 13, no. 4, pp. 1–17, 2021, doi: 10.1177/1687814 0211011862.

[5] Islam M.R., Rahmani M., & Rahman M.H. (2020). A novel exoskeleton with fractional sliding mode control for upper limb rehabilitation. *Robotica, 38*(11), 2099–2120.

[6] Chen C., Zhang S., Zhu X., Shen J., & Zhiyao X. (2020). Disturbance observer-based patient-cooperative control of a lower extremity rehabilitation exoskeleton. // *International Journal of Precision Engineering and Manufacturing, 21*(3), 957–968.

[7] Rahmani M., & Rahman M. H. (2019). Adaptive neural network fast fractional sliding mode control of a 7-DOF exoskeleton robot. // *International Journal of Control, Automation and Systems, 18 (*10), 1–10.

[8] Ezhilarasi D., & Nair A.S. (2021). Modeling and Evaluation of Adaptive Super Twisting Sliding Mode Control in Lower Extremity Exoskeleton. // International Journal of Precision Engineering and Manufacturing-Green Technology, 8(3), 901-915.

[9] Tu Y., Zhu A., Song J., Shen H., Shen Z., Zhang X. and Cao G., 2020. An adaptive sliding mode variable admittance control method for lower limb rehabilitation exoskeleton robot. // Applied Sciences, 10(7), p.2536.

[10] Pérez-San Lázaro R., Salgado I. and Chairez I., 2021. Adaptive sliding-mode controller of a lower limb mobile exoskeleton for active rehabilitation. ISA transactions, 109, pp.218-228.

[11] Truong D.D., Belov M.P., Phuong T.H. Development of Mathematical Model and Subordinate Control for Nonlinear Electric Drivers of Exoskeleton // 2021 IV International Conference on Control in Technical Systems (CTS). IEEE, 2021. С. 131-134.

Глубокое обучение для ранней диагностики диабетической ретинопатии: исследование с использованием сверточной нейронной сети

Али Султан Маея
Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» им. В.И. Ульянова (Ленина)
Alimayya1357@gmail.com

***Аннотация*. В данном исследовании представлен новый подход к автоматизированной диагностике диабетической ретинопатии с использованием моделей глубокого обучения. Предлагаемый способ включает предварительную обработку и подготовку изображений сетчатки, обучение передачи с помощью сети Inception для классификации ретинопатии, обучение U-Net для сегментации изображений сетчатки, мульти-классификацию сегментированных изображений с помощью специально разработанного CNN и объединение моделей CNN для повышения производительности. Для обучения и тестирования использовались наборы данных APTOS 2019 по обнаружению слепоты и драйву. Результаты показали, что начальная сеть достигла точности 87 % для классификации ретинопатии, модель U-Net достигла коэффициента dice 0,95 для сегментации изображений сетчатки, а предлагаемая модель CNN достигла точности 83 % для мульти-классификации сегментированных изображений. Объединенные (ансамблированные) модели CNN привели к общей точности классификации и сегментации ретинопатии в 88,7 %. Предлагаемый метод превзошел предыдущие работы по точности и надежности. Полученные результаты демонстрируют потенциал моделей глубокого обучения для точной и эффективной диагностики диабетической ретинопатии.**

Ключевые слова: диабетическая ретинопатия, сверточные нейронные сети, трансферное обучение, семантическая сегментация, изображения сетчатки, анализ медицинских изображений

I. Введение

Опасный побочный эффект диабета, называемый диабетической ретинопатией, может привести к слепоте или потере зрения. Всемирная организация здравоохранения сообщает, что наиболее распространенной причиной слепоты у лиц трудоспособного возраста во всем мире является диабетическая ретинопатия. Хотя раннее вмешательство может остановить или уменьшить течение заболевания, раннее выявление и лечение диабетической ретинопатии необходимы для предотвращения слепоты [1].

Традиционная диагностика диабетической ретинопатии основывается на ручном исследовании изображений сетчатки офтальмологами, что может отнимать много времени и приводить к ошибкам. Однако недавние достижения в области глубокого обучения и сверточных нейронных сетей (CNN) показали многообещающие результаты в автоматическом выявлении диабетической ретинопатии по изображениям сетчатки [2, 3].

В этой статье мы исследуем применение глубокого обучения и CNNs для ранней диагностики диабетической ретинопатии. В частности, мы исследуем использование трансфертного обучения и сети Inception для классификации изображений сетчатки при диабетической ретинопатии. Мы также предлагаем модель CNN для мульти-классификации ретинопатии на сегментированных изображениях сетчатки с использованием архитектуры U-Net. В исследовании используются два набора данных, Aptos и DRIVE, для обучения и валидации. Набор данных Aptos содержит более 3600 изображений сетчатки, которые были оценены офтальмологами по степени тяжести диабетической ретинопатии по шкале от 0 до 4, в то время как набор данных DRIVE содержит 40 изображений сетчатки с высоким разрешением для сегментации сосудов сетчатки. Мы предварительно обрабатываем набор данных Aptos, используя выравнивание CLAHE и гамма-коррекцию, и дополняем данные, внося исправления для повышения производительности.

Цель нашего исследования – внести свой вклад в растущий объем исследований по применению глубокого обучения и CNNs для автоматической диагностики диабетической ретинопатии. Повышая точность и эффективность диагностики, мы надеемся облегчить раннее вмешательство и, в конечном счете, предотвратить слепоту, вызванную диабетической ретинопатией.

Было проведено множество исследований, подчеркивающих важность методов глубокого обучения, в частности CNNs, для автоматической диагностики диабетической ретинопатии с использованием изображений сетчатки. Многочисленные исследования показали эффективность моделей на основе CNN при классификации диабетической ретинопатии на изображениях сетчатки, причем высокие уровни точности достигаются с использованием методов обучения передаче из предварительно обученных сетей, таких как Inception [2, 3, 4].

Использование небольших наборов данных для анализа медицинских изображений остается сложной задачей, особенно для задач сегментации. Однако применение методов увеличения объема данных показало многообещающие результаты в повышении

производительности сегментации с использованием небольших наборов данных [4, 5].

Методы сегментации, такие как U-Net, также широко используются при анализе медицинских изображений для точной идентификации и выделения патологических областей. U-Net – это широко используемая модель сегментации, которая показала высокую производительность в различных приложениях для анализа медицинских изображений, включая сегментацию изображений сетчатки [5, 6].

Недавние исследования также предложили объединить модели CNN для улучшения эффективности сегментации и классификации. Интеграция различных моделей CNN, обученных различным задачам, может привести к повышению производительности при анализе изображений сетчатки [7, 8].

Предлагаемое исследование использует переносное обучение из Inception network для классификации ретинопатии, U-Net для сегментации изображений сетчатки и предлагает интеграцию этих моделей для достижения улучшенных показателей ранней диагностики диабетической ретинопатии.

II. Материалы и методы

A. *Наборы данных изображений сетчатки*

В этом исследовании использовались два набора данных изображений сетчатки: APTOS 2019 для обнаружения слепоты и DRIVE. Набор данных APTOS содержит 3662 изображения глазного дна сетчатки различного качества, каждое из которых оценивается врачами в соответствии с тяжестью диабетической ретинопатии по шкале от 0 до 4. Набор данных DRIVE содержит 40 изображений сетчатки с высоким разрешением для сегментации сосудов, причем каждое изображение обрезано по полю зрения и предоставлено изображение маски для очерчивания поля зрения [9,10].

B. *Предварительная обработка данных*

Чтобы подготовить изображения сетчатки к обучению и тестированию, был выполнен этап предварительной обработки. Для набора данных APTOS изображения сначала подвергались адаптивному выравниванию гистограммы с ограниченным контрастом (CLAHE) для повышения контрастности изображения и удаления шума. Кроме того, была применена гамма-коррекция для коррекции любого цветового оттенка, присутствующего на изображениях. Для набора данных DRIVE изображения уже были сжаты в формате JPEG и обрезаны по всему полю обзора. Однако для улучшения качества изображения по-прежнему применялись CLAHE и гамма-коррекция [11, 12].

C. *Подготовка наборов данных*

После предварительной обработки набор данных APTOS был дополнен с помощью генератора данных изображений для генерации новых изображений со случайными преобразованиями, такими как вращение, сдвиг и переворачивание. Это было сделано для увеличения размера и разнообразия обучающего набора данных и уменьшения переобучения. Затем расширенный набор данных был разделен на обучающий и валидационный в соотношении 80:20. [13]

Для набора данных DRIVE из каждого изображения были извлечены случайные участки размером 64x64, чтобы создать расширенный набор данных для обучения модели U-Net сегментации изображений сетчатки. Это было сделано, чтобы увеличить количество обучающих выборок и запечатлеть больше локальных особенностей на изображениях. Каждый патч был нормализован и использовался в качестве входных данных для модели вместе с соответствующей ему маской [14].

III. Модели и метод

Для классификации ретинопатии было использовано трансферное обучение с использованием сети Inception, которая была предварительно обучена на базе данных ImageNet. Предварительно обученная начальная сеть была настроена на основе предварительно обработанного набора данных APTOS для классификации изображений сетчатки по пяти уровням тяжести диабетической ретинопатии. Для сегментации изображения сетчатки модель U-Net была обучена на предварительно обработанном наборе данных DRIVE. U-Net — это полностью сверточная архитектура нейронной сети, которая широко используется для сегментации медицинских изображений [4].

Чтобы предложить новую модель CNN для мульти-классификации сегментированных изображений, маски сегментации, сгенерированные моделью U-Net, были введены в специально разработанную архитектуру CNN. Эта модель CNN была обучена классифицировать сегментированные изображения по одному из 5 классов с пятью уровнями тяжести диабетической ретинопатии, но на сегментированных изображениях.

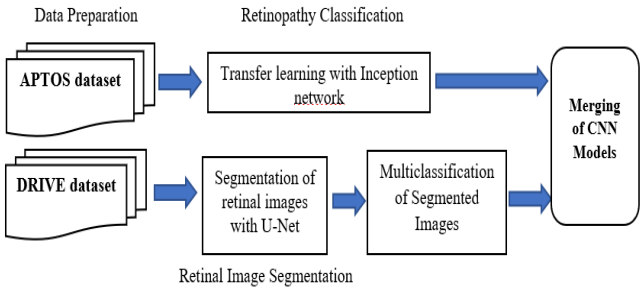

Рис. 1. Принципиальная схема предлагаемого способа

Принципиальная схема предлагаемого метода также демонстрирует, как для объединения двух моделей CNN использовалась стратегия средневзвешенного значения, повышающая производительность сегментации и классификации изображений сетчатки. Это показано на рис. 1.

В целом, этапы предварительной обработки и подготовки помогли обеспечить высокое качество изображений сетчатки и их пригодность для обучения и тестирования моделей CNN. Начальная сеть, модель U-Net и специально разработанная архитектура CNN были эффективны для классификации ретинопатии, сегментации изображений сетчатки и мульти-классификации сегментированных изображений соответственно. Объединение моделей CNN привело к

повышению производительности по сравнению с отдельными моделями.

IV. Результаты

Мы оценили предложенный метод на основе наборов данных APTOS 2019 по обнаружению слепоты и приводу. В следующих подразделах описываются результаты отдельных моделей и предлагаемого метода в целом.

A. Оценка начальной сети по классификации ретинопатии. Начальная сеть была оценена на предмет классификации ретинопатии по набору данных APTOS. Модель достигла точности 87 % в тестовом наборе и смогла с высокой точностью различать пять уровней тяжести диабетической ретинопатии. Матрица путаницы показала, что большинство изображений были классифицированы правильно. Кроме того, кривая ROC для микро-среднего значения имела высокое значение 94 %, что указывает на хорошую производительность модели, на рис. 2 показана кривая ROC для 5 классов.

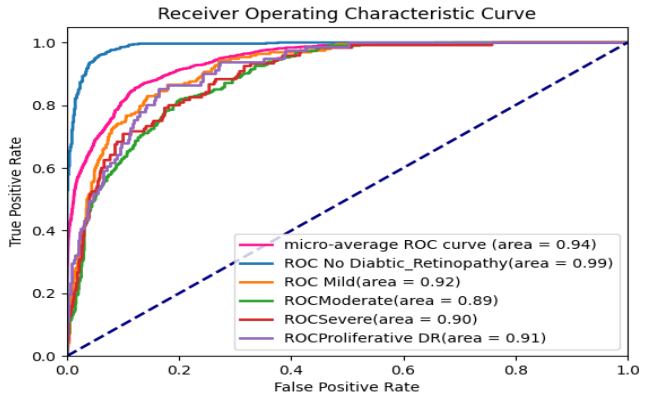

Рис. 2. Roc-кривая трансфертного обучения (transfer learning)

B. Была оценена производительность модели U-Net при сегментации изображений сетчатки, и она достигла среднего коэффициента Dice 0,95 в наборе данных DRIVE, что указывает на хорошую производительность при сегментации кровеносных сосудов сетчатки и диска зрительного нерва. Результаты процесса сегментации можно увидеть на рис. 3, где улучшенная исходная фотография представлена слева в оттенках серого, а сегментированное и результирующее изображение представлено справа.

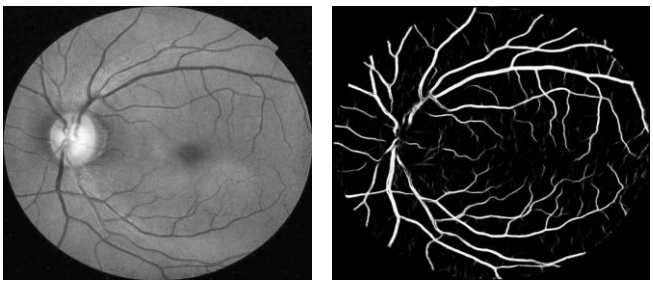

Рис. 3. Результат сегментации изображения

C. Результаты мульти-классификации с использованием предложенной модели CNN: Предложенная модель CNN достигла точности 83 % в тестовом наборе данных APTOS dataset со средней точностью, отзывчивостью и оценкой F1 0,78, 0,78 и 0,80 соответственно. Матрица путаницы показывает, что модель хорошо справилась с классификацией сегментированных изображений.

D. Объединенная модель: Мы объединили начальную сеть и модель CNN, используя метод средневзвешенного значения. Объединенная модель достигла общей точности 88,7 % в тестовом наборе, что является значительным улучшением по сравнению с отдельными моделями.

E. Сравнение предлагаемого метода с предыдущими работами. Мы сравнили производительность предложенного нами метода с предыдущими работами над набором данных APTOS. Наш метод обеспечивает самую современную производительность с точностью 88,7 % на тестовом наборе. Этот результат демонстрирует эффективность предложенного нами метода диагностики диабетической ретинопатии с использованием изображений глазного дна.

ТАБЛИЦА I. РЕЗУЛЬТАТЫ КАЖДОЙ РАЗРАБОТАННОЙ МОДЕЛИ

Метод	Точность	Набор данных
Transfer learning Inception	-87%	- APTOS dataset
U-net для сегментации	-95%	- DRIVE
Предлагаемый неглубокий CNN	-83%	Segmented Retinal images from U-net
Ансамблевая модель	-88.7%	APTOS + Segmented images

V. Заключение

В заключение мы представили новый подход к ранней диагностике диабетической ретинопатии с использованием изображений глазного дна. Предлагаемый нами метод сочетает в себе обучение передаче с сегментацией изображений и моделью CNN для достижения самых современных результатов в наборе данных для обнаружения слепоты APTOS 2019. Наши результаты демонстрируют потенциал использования методов глубокого обучения для ранней диагностики диабетической ретинопатии, что может привести к улучшению результатов у пациентов за счет более раннего лечения.

Будущая работа могла бы быть сосредоточена на повышении точности модели путем включения в анализ дополнительных функций, таких как данные пациента или генетическая информация. Еще одной потенциальной областью для будущих исследований является разработка модели, способной предварительно обрабатывать изображения сетчатки, сделанные камерой смартфона со специально разработанным объективом. Это помогло бы повысить точность модели и могло бы привести к разработке неинвазивной системы мониторинга уровня сахара в крови с использованием изображений сетчатки [14–15].

Таким образом, наше исследование показывает, что методы глубокого обучения могут быть эффективно использованы для ранней диагностики диабетической ретинопатии. Дальнейшие исследования и разработки могут привести к повышению точности и разработке практических приложений для этой технологии в клинических условиях.

СПИСОК ЛИТЕРАТУРЫ

[1] “Diabetes.”https://www.who.int/news-room/fact sheets/detail/diabetes (accessed Mar. 18, 2023).

[2] R. Raman, S. Srinivasan, S. Virmani, S. Sivaprasad, C. Rao, and R. Rajalakshmi, “Fundus photograph-based deep learning algorithms in detecting diabetic retinopathy,” Eye, vol. 33, no. 1, Art. no. 1, Jan. 2019, doi: 10.1038/s41433-018-0269-y.

[3] M. D. Abràmoff, P. T. Lavin, M. Birch, N. Shah, and J. C. Folk, “Pivotal trial of an autonomous AI-based diagnostic system for detection of diabetic retinopathy in primary care offices,” npj Digital Med, vol. 1, no. 1, Art. no. 1, Aug. 2018, doi: 10.1038/s41746-018-0040-6.

[4] O. Ronneberger, P. Fischer, and T. Brox, “U-Net: Convolutional Networks for Biomedical Image Segmentation,” in Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015, Cham, 2015, pp. 234–241. doi: 10.1007/978-3-319-24574-4_28.

[5] A. Oliveira, S. Pereira, and C. A. Silva, “Retinal vessel segmentation based on Fully Convolutional Neural Networks,” Expert Systems with Applications, vol. 112, pp. 229–242, Dec. 2018, doi: 10.1016/j.eswa.2018.06.034.

[6] Z. Mungloo-Dilmohamud, M. Heenaye-Mamode Khan, K. Jhumka, B. N. Beedassy, N. Z. Mungloo, and C. Peña-Reyes, “Balancing Data through Data Augmentation Improves the Generality of Transfer Learning for Diabetic Retinopathy Classification,” Applied Sciences, vol. 12, no. 11, Art. no. 11, Jan. 2022, doi: 10.3390/app12115363.

[7] L. Yu, H. Chen, Q. Dou, J. Qin, and P.-A. Heng, “Automated Melanoma Recognition in Dermoscopy Images via Very Deep Residual Networks,” IEEE Transactions on Medical Imaging, vol. 36, no. 4, pp. 994–1004, Apr. 2017, doi: 10.1109/TMI.2016.2642839.

[8] Y.-M. Chou, Y.-M. Chan, J.-H. Lee, C.-Y. Chiu, and C.-S. Chen, “Unifying and Merging Well-trained Deep Neural Networks for Inference Stage.” arXiv, May 13, 2018. doi: 10.48550/arXiv.1805.04980.

[9] B. Tymchenko, P. Marchenko, and D. Spodarets, “Deep Learning Approach to Diabetic Retinopathy Detection.” arXiv, Mar. 03, 2020. doi: 10.48550/arXiv.2003.02261.

[10] J. Staal, M. D. Abramoff, M. Niemeijer, M. A. Viergever, and B. van Ginneken, “Ridge-based vessel segmentation in color images of the retina,” IEEE Transactions on Medical Imaging, vol. 23, no. 4, pp. 501–509, Apr. 2004, doi: 10.1109/TMI.2004.825627.

[11] S. M. Pizer et al., “Adaptive histogram equalization and its variations,” Computer Vision, Graphics, and Image Processing, vol. 39, no. 3, pp. 355–368, Sep. 1987, doi: 10.1016/S0734-189X(87)80186-X.

[12] R. A. Welikala et al., “Automated detection of proliferative diabetic retinopathy using a modified line operator and dual classification,” Computer Methods and Programs in Biomedicine, vol. 114, no. 3, pp. 247–261, May 2014, doi: 10.1016/j.cmpb.2014.02.010.

[13] P. Arora, V. M. Kapse, S. Sinha, and S. Gera, “An analytical study for Pneumonia Detection towards building an intelligent system using Image Data Generator,” in 2021 9th International Conference on Reliability, Infocom Technologies and Optimization (Trends and Future Directions) (ICRITO), Sep. 2021, pp. 1–4. doi: 10.1109/ICRITO51393.2021.9596434.

[14] S. Kumari, P. Venkatesh, N. Tandon, R. Chawla, B. Takkar, and A. Kumar, “Selfie fundus imaging for diabetic retinopathy screening,” Eye, vol. 36, no. 10, Art. no. 10, Oct. 2022, doi: 10.1038/s41433-021-01804-7.

[15] T. H. Rim et al., “Prediction of systemic biomarkers from retinal photographs: development and validation of deep-learning algorithms,” The Lancet Digital Health, vol. 2, no. 10, pp. e526–e536, Oct. 2020, doi: 10.1016/S2589-7500(20)30216-8.

Цифровизация процесса выявления дефектов на изделиях из силицированного графита с помощью нейронных сетей

И. В. Друмов, М. А. Камнев, Г. С. Малышев, Г. В. Терехин*
АО «ОКБМ Африкантов», Нижний Новгород
*terekhin2412@gmail.com

***Аннотация*. Статья относится к работе в области цифровизации в атомной промышленности. В работе анализируются результаты работы нейронной сети, формы искусственного интеллекта. Нейронная сеть предназначается для классификации дефектов на изделиях из силицированного графита. Даются рекомендации по её использованию. Обученная сеть позволяет частично автоматизировать процедуру осмотра изделий и существенно уменьшить время осмотра, что и обуславливает актуальность проведённого исследования.**

В статье показано, что в случае распознавания дефектов достаточно использовать сети достаточно простой архитектуры. Полносвязный классификатор сети обучался для решения задачи классификации изображений по пяти категориям: дефекты типа «трещина», дефекты типа «скол», дефекты типа «отдельная пора», дефекты типа «скопление пор» и «бездефектная поверхность». В статье приводится архитектура полносвязного классификатора сети, а также настройки, использованные при обучении сети.

Ключевые слова: валидационный набор; дефекты; машинное зрение; нейронные сети; распознавание; силицированный графит; тестовый набор; цифровизация

I. Введение

Проектирование и создание электронасосов для атомной промышленности – одно из важных направлений деятельности АО «ОКБМ Африкантов». Качество пар трения подшипниковых узлов электронасосов определяет ресурс работы насосного оборудования. При исследовании подшипниковых изделий определяется интенсивность изнашивания, коэффициент трения, стойкость в среде воды, наличие дефектов на материале пары трения.

В целях повышения качества контроля образцов и сокращения времени протекания процесса осмотра образцов предлагается использовать цифровые методы осмотра подшипниковых изделий с помощью свёрточных нейронных сетей, которые позволят производить классификацию дефектов на изделиях [1].

В ходе выполнения работ, описанных в статье, обучена нейронная сеть, производящая классификацию по пяти категориям: дефекты типа «трещина», дефекты типа «скол», дефекты типа «отдельная пора», дефекты типа «скопление пор» и «бездефектная поверхность». Указанные четыре типа дефектов являются наиболее распространёнными на изделиях из силицированного графита.

II. Формирование обучающего, валидационного и тестового наборов

Для обучения нейронной сети сформирована обучающая выборка, в которой представляются изображения наиболее характерных дефектов. Для корректного обучения сети необходим набор валидации, то есть набор данных для проверки результатов работы нейронной сети.

В процессе обучения данные из валидационного набора «просачиваются» в сеть [2]. Поэтому нужна дополнительная проверка работоспособности обученной сети на тестовом наборе, который отличен от набора валидации.

III. Архитектура нейронной сети в случае малой обучающей выборки

При выборе архитектуры сети исследователи из АО «ОКБМ Африкантов» исходили из того, что информация о дефектах должна быть заложена в наиболее обобщенных (локальных) признаках, самыми сложными из которых могут быть, например, ломаные линии (признак трещины), затемнения на поверхности или большие скопления мелких тёмных пятен (признак скопления пор), нарушение строгой геометрии на краях изделия (признак скола), одиночное пятно (признак отдельной поры), большие участки поверхности с равномерной текстурой (признак бездефектной поверхности) [2]. На рис. 1 показан пример канала, который активируется на одном из данных признаков (рисунки получены для сети VGG16, обученной на тренировочном наборе ImageNet) [1, 2]. Более глубокие слои сети выделяют абстрактные понятия, то есть признаки высокого уровня [2]. В случае дефектов, говорить о каких бы то ни было абстрактных признаках достаточно сложно, так как дефекты выглядят аморфно.

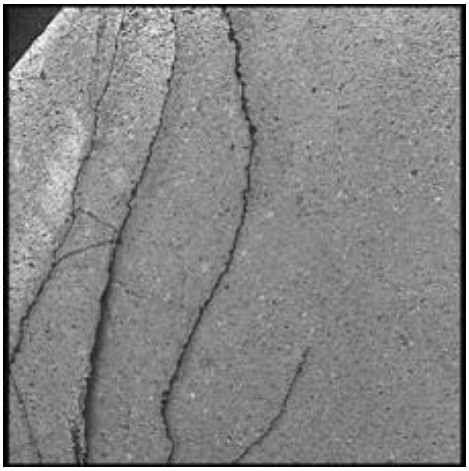

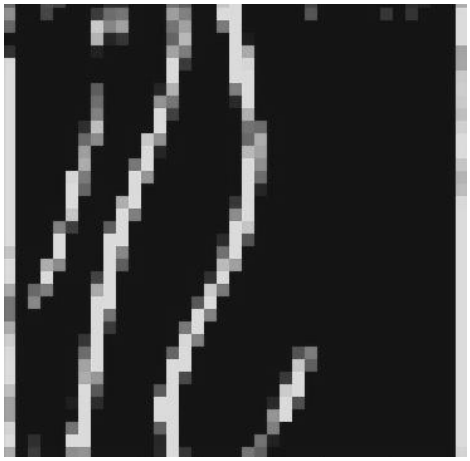

Рис. 1. Пример дефекта типа «трещина» и соответствующий ему канал активации. Активация происходит на ломаных линиях, которые являются признаком трещины

Изначально была сделана попытка решить задачу распознавания дефектов с помощью сети AlexNET [2]. Сеть обучалась «с нуля» с помощью функций библиотеки Keras, написанной на языке Python.

Обученная сеть показала плохие результаты работы: доля правильно распознанных изображений из тестового набора составила всего 72 %, в то время как требуемая точность составляет не менее 85 %.

Таким образом, было принято решение отказаться от дальнейших попыток обучения (дообучения) сети AlexNET и попробовать использовать сеть VGG16, обученную на миллионе изображений (1000 изображений на категорию) из тренировочного набора ImageNet [4]. Использование предобученной сети позволило избежать многих трудностей.

В качестве метода оптимизации по-прежнему был выбран метод RMSprop. Начальная скорость обучения устанавливалась в $2 \cdot 10^{-5}$. Размер минибатча был равен пяти. Полносвязный классификатор был обучен за 40 эпох, после чего значения точности распознавания (процент правильно распознанных изображений из набора валидации) и перекрёстной энтропии, практически перестают изменяться (рис. 2 и рис. 3). Время обучения заняло порядка полутора минут (то есть меньше, чем обучение сети AlexNET с нуля).

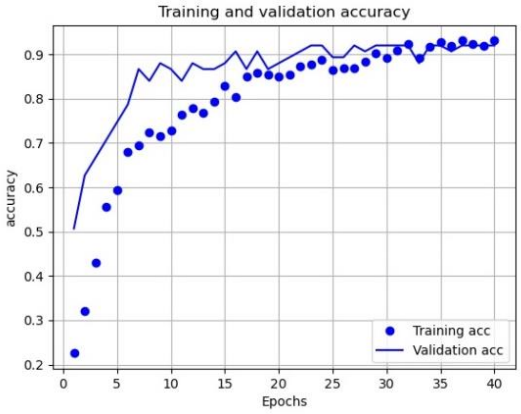

Рис. 2. Процесс изменения доли правильно распознанных изображений в процессе обучения

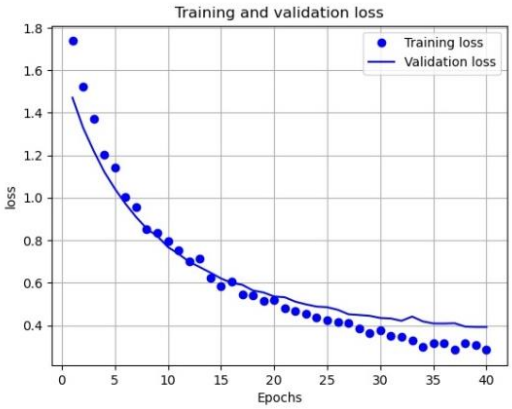

Рис. 3. Процесс изменения перекрёстной энтропии в процессе обучения

После обучения сети точность классификации изображений на наборе валидации достигает 92 % (69 изображений из 75 валидационных). Проверка на тестовом наборе (50 изображений) показала, что точность работы обученной сети составляет 90 % (45 изображений из 50 тестовых).

IV. Анализ результатов работы обученной сети

Наиболее сложной является классификация дефектов типа «скопление пор», поэтому особый интерес представляют результаты распознавания таких дефектов с помощью обученной нейронной сети. Примеры распознанных дефектов типа «скопление пор» представлены на рис. 4, из которого видно, что сеть успешно справляется с задачей распознавания даже в сложных случаях.

В тестовом наборе из 50 изображений были неправильно идентифицированы только 5 изображений. В наборе валидации из 75 изображений были неправильно идентифицированы 6 изображений (на момент окончания обучения). Два из одиннадцати неправильно распознанных изображений плохо классифицируются даже опытным оператором. Шесть изображений – это «нехарактерные» для обучающей выборки изображения. Например, на одном неправильно идентифицированном изображении большую часть изображения занимает фон, который заметно светлее самого изделия. Такие изображения не следует предъявлять сети.

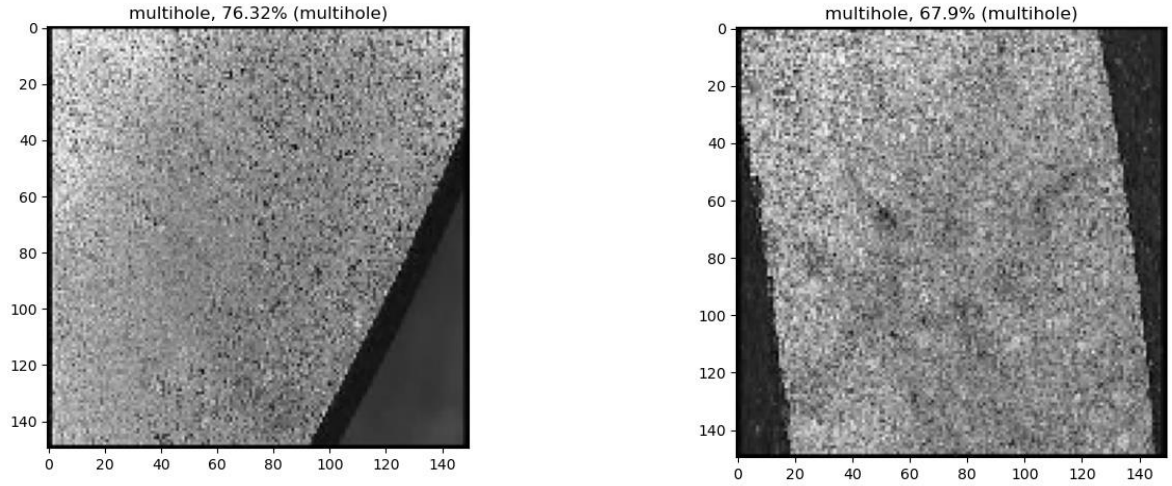

Рис. 4. Дефекты типа «скопление пор», успешно распознанные сетью

V. Практическое использование обученной сети

Для формирования рекомендаций по использованию сети, нужно в первую очередь исходить из анализа ошибок, допущенных сетью. Если инженера интересует не только факт наличия дефекта, но и его тип, то всякий вердикт, вынесенный сетью с вероятностью менее 60 %, должен считаться сомнительным. Такие «сомнительные» изображения необходимо отправлять опытному специалисту для вынесения окончательного решения. Однако, среди всех тестовых и валидационных изображений (в общей сложности 125 изображений) нашлось только 21 изображение, для которых сеть вынесла вердикт с предсказательной вероятностью менее 60 %. То есть грубая оценка показывает, что обученная нейронная сеть экономит 83 % (104 изображения от 125) времени на исследование образцов из силицированного графита.

Если исследователя интересует только факт наличия дефекта на поверхности, то обученная сеть сэкономит 95 % (119 изображения от 125) времени на исследование образцов.

VI. Заключение

Рассмотрен перспективный способ цифровизации процесса осмотра изделий из силицированного графита, основанный на использовании свёрточных нейронных сетей. Путём анализа количества ошибок, допущенных сетью, были даны рекомендации по практическому использованию сети. Показано, что обученная нейронная сеть позволит экономить до 83 % времени при классификации дефектов по четырём категориям. В случае бинарной классификации (выявляется только факт наличия дефекта) обученная сеть сэкономит до 95 % времени на исследование образцов.

Показано, что при малом обучающем наборе (55 изображений на категорию) использование предобученной сети позволяет существенно повысить процент правильно распознанных дефектов по сравнению со случаем, когда сеть обучалась с нуля. Обученный полносвязный классификатор, принимающий карты признаков из свёрточной сети VGG16, достигает точности распознавания 90 % на тестовом множестве и 92 % на валидационном множестве. При этом обучался только полносвязный классификатор, а свёрточная основа сети оставалась без изменений.

Сделана попытка объяснения высокого процента правильно распознанных дефектов (90 % на тестовом множестве) при условии малости обучающей выборки: данный эффект скорее всего связан с тем, что для дефектов не требуется выявлять каких бы то ни было абстрактных признаков. В то же время наиболее обобщённые признаки, характерные, в том числе и для дефектов, должны выявляться уже первыми свёрточными слоям предобученной сети.

Список литературы

[1] Архангельская Е.В., Кадурин А.А., Николенко С.И. Глубокое обучение. Погружение в мир нейронных сетей. СПб.: Питер, 2020. 481 с.

[2] Шолле Ф. Глубокое обучение на Python. СПб.: Питер, 2020. 400 с.

[3] Hinton G.E., Krizhevsky A., Sutskever I. ImageNet Classification with Deep Convolutional Neural Networks. Advances in Neural Information Processing Systems 25 / Curran Associates, 2012. p. 1097–1105.

[4] Simonyan K., Zisserman A. Very Deep Convolutional Networks for Large-Scale Image Recognition – arXiv:1409.1556v6 [cs.CV], 10 April – 2015.

Использование вариационного автокодировщика для расширения обучающего набора нейронной сети, распознающей дефекты на изделиях из силицированного графита

Г. С. Малышев, И. В. Друмов, М. А. Камнев, Г. В. Терехин
АО «ОКБМ Африкантов», Нижний Новгород
gsmalyshev@okbm.nnov.ru

Аннотация. **Проверяется возможность и целесообразность использования вариационных автокодировщиков при расширении обучающих датасетов нейронных сетей для случаев, когда набор обучения состоит из нескольких десятков образцов. Исследования проводятся на примере изображений дефектов типа «трещина». Приводятся краткие сведения из теории вариационных автокодировщиков. Даются практические рекомендации для построения обучающих наборов вариационных автокодировщиков. Показывается, что отклонение от предложенных рекомендаций, скорее всего, не позволит сгенерировать реалистичных изображений при малом датасете. Для случая датасета из восьмидесяти изображений демонстрируется распределения дефектов типа «трещина» в скрытом пространстве после обучения вариационного автокодировщика. Приводятся примеры изображений с дефектами, сэмплированных из разных частей распределения скрытых факторов. Для случая изображений трещин демонстрируется непрерывность скрытого пространства, когда одно изображение достаточно плавно трансформируется в другое по пути через пространство скрытых признаков. Предлагается метод получения наложенных изображений, основанный на использовании вариационных автокодировщиков.**

Ключевые слова: нейронные сети; энкодер; декодер; вариационные автокодировщики; пространство скрытых факторов; сэмплирование из скрытого пространства; генеративные модели; дефекты; минибатч; обучающий набор сети

I. Введение

Важная задача, которая стоит перед специалистами большинства производственных предприятий, – это визуальный осмотр поверхности изделий на предмет наличия дефектов. В целях повышения качества контроля образцов и сокращения времени осмотра образцов предлагается использовать свёрточную нейронную сеть [1–2], которая позволит производить классификацию дефектов на изделиях. Одна из основных проблем, с которой сталкиваются исследователи при обучении нейронных сетей, – это малое количество изображений с дефектами, на которых будет обучаться сеть. Появление генеративно-состязательных сетей [3–6] и вариационных автокодировщиков [7–10] естественно приводит к идее о применении данных порождающих моделей для расширения набора обучающих данных. Целью настоящей статьи является проверка возможности и целесообразности использования вариационных автокодировщиков для расширения малых обучающих наборов.

II. Понятие вариационного автокодировщика

Автокодировщик – это устройство, которое состоит из двух частей – энкодера и декодера. Задача энкодера – понижать размерность входных данных, например, изображений. Например, мы имеем чёрно-белое изображение, которое состоит из D пикселей. Это изображение рассматриваем как вектор в D-мерном пространстве. Задача энкодера состоит в том, чтобы отобразить D-мерный вектор в вектор меньшей размерности d. Само d-мерное пространство векторов называют скрытым (латентным) или пространством скрытых факторов. Полученный d-мерный вектор несёт в себе информацию о самых характерных признаках исходных изображений. Задача декодера состоит в том, чтобы отобразить скрытый вектор в изображение, максимально похожее на исходное. В качестве энкодера и декодера выступают нейронные сети.

Основная идея вариационных автокодировщиков [7–10] состоит в том, что координаты векторов скрытого пространства рассматриваются как непрерывные случайные величины со своим матожиданием и дисперсией, а сеть энкодера порождает не сами скрытые вектора, а параметры их распределений, то есть матожидание и дисперсию [11–12]. Таким образом, сеть энкодера должна иметь d выходов: d выходов – это математические ожидания компонент скрытого вектора, остальные выходы – стандартные отклонения компонент. Сеть декодера будет иметь d входов. Полученное после обучения автокодировщика распределение точек скрытого пространства должно быть близко к нормальному распределению с нулевым вектором математического ожидания.

С учётом результатов исследований, представленных в источниках [7–8, 13], можно сделать вывод, что обучающие изображения, несущие некоторый существенный признак (например, улыбку на лице человека), не должны существенно различаться. В противном случае в процессе обучения может быть выделен некоторый кластер скрытого пространства, который кодирует незначительные признаки [14], например, текстуру фона.

III. Попытка плавного сэмплирования изображений с трещинами в случае малого обучающего набора

В качестве примера будем рассматривать изображения дефектов типа «трещина». Набор состоит из 80 чёрно-белых изображений. Примеры некоторых из

них представлены на рис. 1. На данных изображениях можно выявить три существенных признака: ломаные линии (признак непосредственно самой трещины), текстура поверхности изделия, а также резкие переходы (границы изделий). Для простоты визуализации будем рассматривать двумерное скрытое пространство. Задача состоит в том, чтобы попытаться сконструировать скрытые вектора, которые кодируют данные существенные признаки.

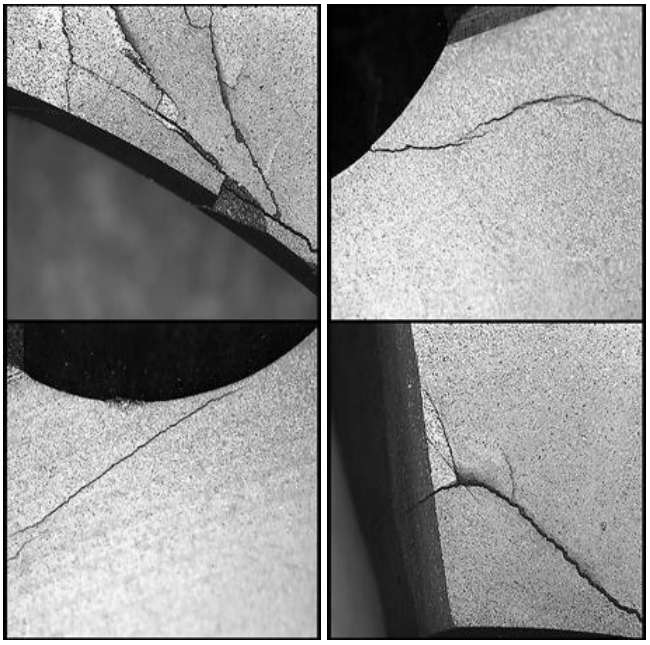

Рис. 1. Примеры дефектов типа «трещина» из обучающего датасета автокодировщика

В основу вариационного автокодировщика была положена архитектура, предложенная в источнике [15]. Обучение производилось в течение 100 эпох, размер минибатча был равен 10. В качестве метода оптимизации был выбран метод RMSprop [1]. При обучении сети с помощью функций библиотеки Keras начальная скорость обучения устанавливалась в $2 \cdot 10^{-3}$. Остальные параметры алгоритма RMSprop, а также начальные значения весов и порогов были оставлены по умолчанию.

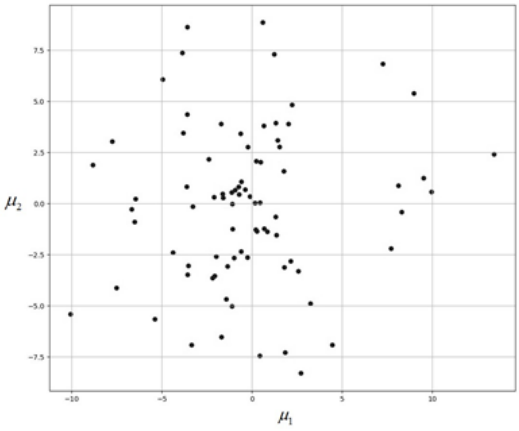

Рис. 2. Представление распределения дефектов типа «трещина»

Представление распределения дефектов типа «трещина» в скрытом пространстве после обучения представлено на рис. 2. Точками на рисунке показаны координаты $\{\mu_1(x_i), \mu_2(x_i)\}$ векторов математического ожидания, полученные для изображений x_i из обучающего набора. Можно отметить, что полученное распределение действительно в первом приближении напоминает нормальное с нулевым матожиданием. В полученном распределении сложно выявить области, кодирующие один из трёх существенных признаков. В первую очередь важно найти скрытые вектора, кодирующие ломаные линии. Из рис. 2 можно оценить область, из которой будут выбираться скрытые вектора: для генерации искусственных изображений на первый входной нейрон декодера нужно подавать значения из сегмента [-15; 15], а на второй входной нейрон значения из сегмента [-10; 10]. Будем двигаться с шагом 0,1 по каждому сегменту. Примеры полученных изображений представлены на рис. 3.

Хорошо видно, что в процессе обучения удалось эффективно закодировать только один существенный признак – резкие переходы, то есть границы изделий (рис. 1). Кроме того, была выявлена область скрытого пространства, которая кодирует трещины на изображениях. Изображения на рис. 3 хорошо демонстрируют непрерывность скрытого пространства, когда одно изображение достаточно плавно трансформируется в другое по пути через пространство скрытых признаков.

Однако, все трещины, которые можно различить на сгенерированных изображениях – это только незначительная часть из датасета. Интересно отметить, что трещины на рис. 3 практически всегда двойные, то есть одна трещина тянется вдоль другой. Возможно, именно такая структура дефектов была понята автокодировщиком как существенный признак.

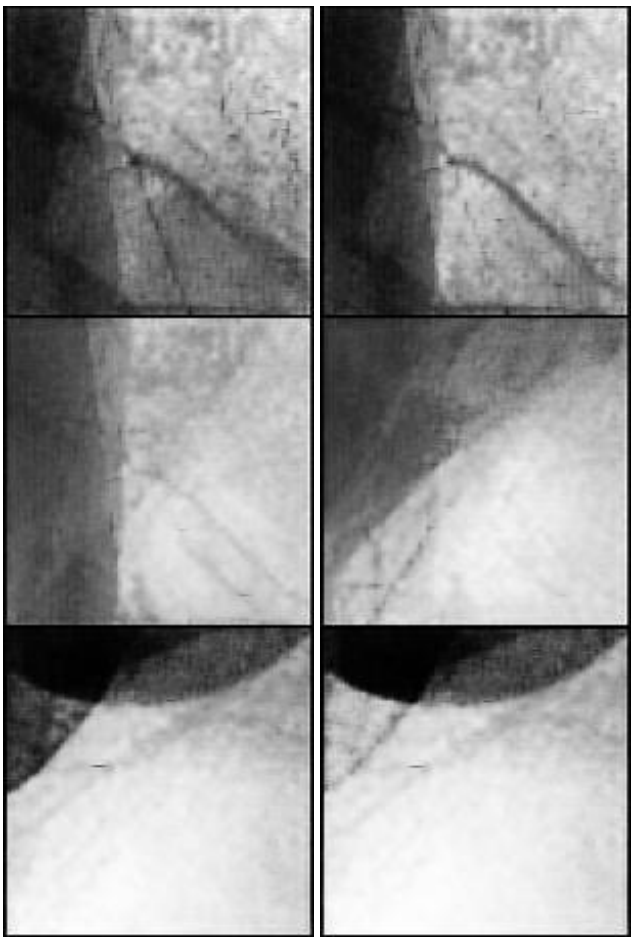

Рис. 3. Примеры изображений с трещинами, сэмплированных из разных частей распределения скрытых факторов

Объяснение данному эффекту было дано ранее: при построении скрытого вектора, кодирующего некоторый существенный признак, обучающие изображения, несущие этот признак, не должны существенно различаться. То есть изначально обучающий пакет был подготовлен некорректно. Из образцов, представленных на рис. 1, хорошо видно, что все ломаные линии на изображениях имеют разную ориентацию, геометрические размеры и структуру. Кроме того, для трещин нельзя выявить абстрактных признаков (таковыми являются, например, губы на лице человека), поэтому требование, согласно которому абстрактные признаки не должны быть существенно смещены друг относительно друга на фотографиях из обучающего набора, теряет свою корректность.

Приведённый пример показал, что использование малого количества значительно различающихся изображений, скорее всего не позволит существенно расширить обучающую выборку с помощью вариационного автокодировщика, так как возникают большие сложности с конструированием скрытого вектора, определяющего геометрию трещин.

IV. Метод наложения изображений

Требование близкого расположения существенных признаков на изображениях из обучающего набора важно соблюдать только в тех случаях, когда имеется малый набор обучения, и при этом требуется получить плавные переходы между генерируемыми изображениями. Малый же набор (порядка сотни изображений) из существенно различающихся изображений можно использовать для получения наложенных изображений, когда сгенерированное изображение представляет наложение нескольких изображений с трещинами.

Чем сильнее различаются группы изображений, тем дальше будут разнесены вектора, которые кодируют существенные признаки для разных групп изображений. Для получения наложенного изображения суммируются векторы из отдалённых кластеров, полученный вектор подаётся на декодер [1–2].

Основная идея, положенная в основу получения наложенных изображений, состоит в том, что существенные признаки нужно выделять для каждого изображения в отдельности. В итоге в скрытом пространстве будут получены разрозненные кластеры, в которых закодированы существенные признаки каждого изображения (число кластеров будет равно исходному количеству изображений). Для этого нужно подготовить множество копий (не менее пятисот) для каждого изображения.

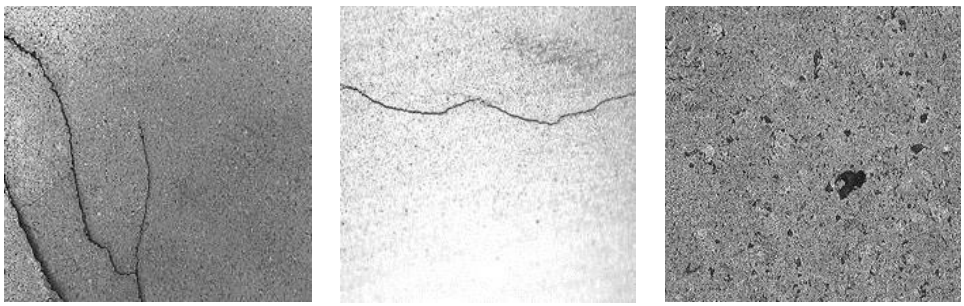

а) б) в)

Рис. 4. Образцы изображений, на базе которых будут генерироваться наложенные изображения

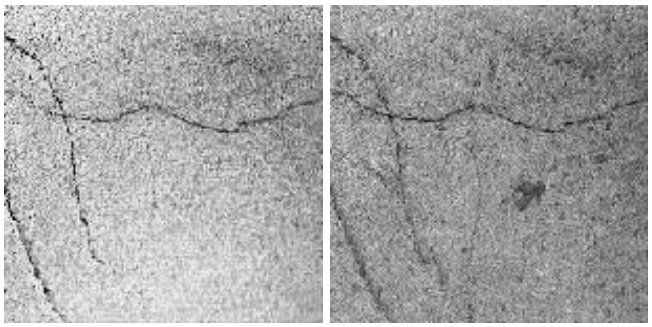

Рис. 5. Примеры наложенных изображений с дефектами, полученных с помощью вариационного автокодировщика на базе изображений рис. 4

Проиллюстрируем предлагаемый приём. Ограничимся только тремя изображениями, представленными на рис. 4. Будем генерировать изображение, на котором совместятся эти дефекты (два дефекта типа «трещина» и дефект типа «пора»). Создадим по 500 копий на каждый из дефектов. Архитектура энкодера и декодера была оставлена прежней, размерность скрытого пространства равна двум. Внутри минибатча должны быть представлены образцы тех изображений, которые мы хотим совместить. Обучение произведено за 20 эпох.

Трещины на сгенерированном изображении (рис. 5) выглядят более чётко, нежели пора, так как в обучающем наборе изображений с трещинами было в два раза больше. Реалистичность изображения можно повысить путём повышения размерности скрытого пространства. На следующем этапе исследований предполагается использовать полученные наложенные изображения для расширения обучающего датасета, предназначенного для обучения нейронных сетей под задачи классификации. Сравнение процента правильно распознанных изображений для случаев, когда сеть обучалась на исходном и расширенном наборах, позволит оценить эффективность использования сгенерированных изображений в процессе обучения сети.

V. Заключение

Приведены краткие сведения из теории ВАК, сформулированы рекомендации по подготовке обучающих наборов для ВАК. Для критически малого набора из 80 изображений сделана попытка обучить ВАК под задачу построения плавного перехода

(интерполяции) между всеми обучающими изображениями с трещинами. Показано, что на таком малом наборе сети энкодера и декодера не могут выявить универсальный существенный признак, присущий всем трещинам. Однако, после обучения ВАК были выявлены скрытые вектора, кодирующие трещины с двойной структурой. Для соответствующей области пространства скрытых факторов была продемонстрирована непрерывная трансформация одного изображения в другое. Возможность непрерывной генерации изображений для ВАК, обученных на столь малом наборе, демонстрируется впервые в научно-технической литературе. Тот факт, что нейронные сети энкодера и декодера ВАК выявили существенные признаки только для части трещин из набора обучения связан с тем, что трещины из набора существенно отличаются ориентацией, геометрическими размерами и структурой.

Исходя из теоретических сведений, положенных в основу ВАК, была предложена методика генерации наложенных изображений, которая может быть успешно использована даже для случая двух обучающих изображений. Предложенный в статье метод наложения изображений позволил получить реалистичные изображения дефектов.

Список литературы

[1] Архангельская Е.В., Кадурин А.А., Николенко С.И. Глубокое обучение. Погружение в мир нейронных сетей. СПб.: Питер, 2020. 481 с.

[2] Шолле Ф. Глубокое обучение на Python. СПб.: Питер, 2020. 400 с.

[3] Generative Adversarial Networks / I.J. Goodfellow et al. // ArXiv e-prints, 2014.

[4] Goodfellow I.J. NIPS 2016 Tutorial: Generative Adversarial Networks // arXiv, 2017. http://arxiv:org/abs/1701:00160.

[5] Nowozin S., Cseke B., Tomioka R. f-GAN: Training Generative Neural Samplers using Variational Divergence Minimization // Advances in Neural Information Processing Systems 29 / Curran Associates, Inc., 2016. P. 271–279.

[6] Radford A., Metz L., Chintala S. Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks // arXiv, 2015. http://arxiv:org/abs/1511:06434.

[7] Kingma D.P., Welling M. Auto-Encoding Variational Bayes // arXiv:1312.6114v10 [stat.ML], 1 May – 2014.

[8] Doersch C. Tutorial on Variational Autoencoders // arXiv:1606.05908v3 [stat.ML], 3 Jan – 2021.

[9] Nonparametric Variational Auto-encoders for Hierarchical Representation Learning / P. Goyal et al. // arXiv, 2017. http://arxiv:org/abs/1703:07027.

[10] On Unifying Deep Generative Models / Z. Hu et al. // arXiv, 2017. http://arxiv:org/abs/1706:00550.

[11] MacKay D. J. C. A Practical Bayesian Framework for Backpropagation Networks // Neural Computation, 1992, vol. 4, no. 3. P. 448–472.

[12] Neal R.M. Bayesian Learning for Neural Networks, Secaucus, NJ, USA: Springer-Verlag New York, Inc., 1996.

[13] Metzen J.H. Variational Autoencoder in TensorFlow, 2015. https://jmetzen:github:io/2015-11-27/vae:html.

[14] Variational Lossy Autoencoder / X. Chen et al. // arXiv, 2016. http://arxiv:org/abs/1611:02731.

[15] https://keras.io/examples/generative/vae/

УДК 004.032.26

Искусственные фотонные нейронные сети: принципы построения и способы реализации

М. Е. Белкин, К. В. Шабельник
МИРЭА – Российский Технологический университет
belkin@mirea.ru, skvmf@mail.ru

***Аннотация*. Рассматриваются основные принципы построения и реализации искусственных фотонных нейронных сетей, являющихся базовой технологией концепции построения искусственного интеллекта. Описываются этапы построения искусственных фотонных нейронных сетей. Рассматриваются различные подходы к созданию таких сетей, включая использование оптических элементов и фотонных кристаллов. Также описываются различные области применения искусственных фотонных нейронных сетей.**

Ключевые слова: искусственные фотонные нейронные сети, фотонные кристаллы, оптические элементы

I. Введение

Искусственные фотонные нейронные сети – это новый класс нейросетевых систем, основанных на использовании фотонных элементов в качестве базовых строительных блоков [1]. Они являются перспективным направлением в разработке вычислительных систем, обладающих высокой энергоэффективностью и скоростью работы.

В последние годы искусственные нейронные сети стали широко используемым инструментом в различных областях, таких как компьютерное зрение, обработка естественного языка и распознавание речи. Однако, существует потребность в более быстрых и эффективных методах обработки информации, которые могут быть реализованы с помощью фотонных технологий.

Фотонные нейронные сети представляют собой новый подход к обработке информации, который основан на использовании света вместо электрических сигналов. Это позволяет ускорить процесс обработки информации и уменьшить энергопотребление.

II. Принципы построения искусственных фотонных нейронных сетей

Искусственные фотонные нейронные сети (Artificial Photonic Neural Networks, APNN) представляют собой новый класс нейронных сетей, основанных на использовании света в качестве информационного носителя (рис. 1). Они могут обрабатывать информацию с высокой скоростью и эффективностью, что делает их привлекательными для решения широкого спектра задач машинного обучения.

Исследование выполнено за счет гранта Минобрнауки РФ (грант в форме субсидии, шифр темы FSFZ-2022-0005)

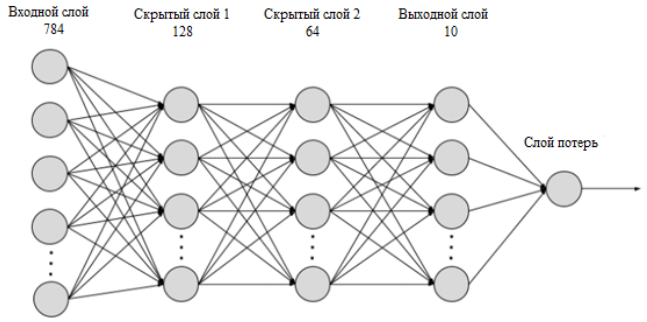

Рис. 1. Пример структурной схемы ИНС

Фотонные нейронные сети основаны на принципах работы биологических нейронных сетей. Они состоят из множества узлов-нейронов, каждый из которых обрабатывает информацию и передает ее дальше. Каждый нейрон имеет несколько входов и один выход. Входы получают сигналы от других нейронов или от внешних источников, а выход передает результат обработки дальше по сети.

В отличие от электронных нейронных сетей, где информация обрабатывается с помощью электрических сигналов, фотонные нейронные сети используют световые волны. Фотоны, как и электроны, могут передавать информацию через узлы-нейроны и взаимодействовать друг с другом [2].

Процесс построения фотонных нейронных сетей включает следующие этапы:

- определение архитектуры сети: выбор количества слоев, числа нейронов в каждом слое и типа функций активации;
- разработка фотонных элементов: создание элементов, которые могут обрабатывать информацию в виде световых импульсов, таких как лазеры, фотодетекторы, световоды, микрокольца и т. д.;
- интеграция фотонных элементов: соединение фотонных элементов в сеть, с учетом архитектуры сети;
- обучение сети: настройка параметров сети для достижения желаемого результата. Обучение может быть проведено методами обратного распространения ошибки или другими методами машинного обучения;
- оптимизация сети: оптимизация параметров сети для улучшения ее производительности и эффективности;

- тестирование сети: проверка работоспособности и точности сети на тестовых данных.

Таким образом, искусственные фотонные нейронные сети представляют собой инновационный подход к созданию нейронных сетей, который может быть использован для решения различных задач машинного обучения.

III. Способы реализации искусственных фотонных нейронных сетей

Существует несколько способов реализации фотонных нейронных сетей [3]. Один из них основан на использовании оптических волноводов и модуляторов для передачи и обработки информации. Другой способ основан на использовании светочувствительных материалов, которые могут изменять свой индекс преломления под воздействием света.

Важным компонентом фотонных нейронных сетей являются фотодетекторы, которые преобразуют световой сигнал в электрический. Они позволяют получить выходной сигнал от каждого нейрона, который можно передать дальше по сети.

Для обучения фотонных нейронных сетей используются различные алгоритмы, такие как обратное распространение ошибки и генетические алгоритмы. Они позволяют настраивать веса между нейронами, чтобы достичь оптимальной работы сети [4].

Рассмотрим поподробнее каждый из способов реализации искусственных фотонных нейронных сетей:

- использование интегральной оптики: в этом случае фотонные элементы создаются на основе интегральной оптики, которая позволяет создавать микросхемы, содержащие световоды, микрокольца и другие элементы. Это позволяет создавать компактные и эффективные фотонные нейронные сети;

- использование оптических волокон: в этом случае световоды и другие фотонные элементы создаются на основе оптических волокон. Это позволяет создавать длинные и сложные сети, которые могут обрабатывать информацию на больших расстояниях;

- использование фотонных кристаллов: в этом случае фотонные элементы создаются на основе фотонных кристаллов, которые могут управлять светом с высокой точностью. Это позволяет создавать сети с высокой производительностью и точностью;

- использование гибридных подходов: в этом случае фотонные элементы создаются на основе комбинации различных технологий, таких как интегральная оптика, оптические волокна и фотонные кристаллы. Это позволяет создавать сети с различными свойствами и характеристиками.

Каждый из этих способов имеет свои преимущества и недостатки, и выбор конкретного способа зависит от конкретной задачи и требований к сети.

IV. Применение искусственных фотонных нейронных сетей

Искусственные фотонные нейронные сети могут быть использованы в различных областях, включая [5]:

- обработка сигналов: фотонные нейронные сети могут использоваться для обработки сигналов, таких как звуковые и видео сигналы. Они могут обрабатывать большие объемы данных на высокой скорости и с высокой точностью;

- распознавание образов: фотонные нейронные сети могут использоваться для распознавания образов, например, для распознавания лиц или автомобильных номеров. Они могут быть очень быстрыми и точными в этой задаче;

- криптография: фотонные нейронные сети могут использоваться для криптографических задач, таких как шифрование и дешифрование информации. Они могут быть более защищенными от атак хакеров, чем традиционные методы шифрования;

- медицина: фотонные нейронные сети могут быть использованы в медицине для анализа медицинских изображений, например, для диагностики рака. Они могут быть более точными и быстрыми, чем традиционные методы анализа;

- интернет вещей: фотонные нейронные сети могут быть использованы в интернете вещей для обработки больших объемов данных и принятия решений на основе этих данных. Они могут быть более эффективными и быстрыми, чем традиционные методы обработки данных.

В целом, искусственные фотонные нейронные сети представляют собой новую и перспективную технологию, которая может быть использована во многих областях. Они могут быть более эффективными и точными, чем традиционные методы обработки данных, и могут иметь большой потенциал для развития в будущем.

V. Заключение

Из вышесказанного следует, что искусственные фотонные нейронные сети представляют собой перспективное направление в разработке вычислительных систем нового поколения. Реализация фотонных нейронных сетей требует использования специализированных компонентов, таких как оптические волноводы и светочувствительные материалы [6]. В будущем ожидается расширение областей применения фотонных нейронных сетей и улучшение их характеристик.

Искусственные фотонные нейронные сети могут быть использованы в различных областях, таких как оптическая связь, обработка изображений, распознавание речи и других задачах машинного обучения. Они могут значительно ускорить вычисления и снизить энергопотребление, что делает их перспективным направлением в развитии вычислительных систем.

Фотонные нейронные сети представляют собой инновационный подход к обработке информации, который может привести к значительному ускорению и оптимизации процессов в различных областях. Однако, этот подход все еще находится на начальной стадии развития, и требует дальнейших исследований и разработок для его оптимизации и расширения возможностей применения.

Таким образом, можно сделать вывод, что фотонные нейронные сети могут стать важным инструментом для решения сложных комплексных задач в различных направлениях науки, производства и бизнеса.

СПИСОК ЛИТЕРАТУРЫ

[1] Головастиков Н.В., Дорожкин П.С., Сойфер В.А. Интеллектуальные технические системы на основе фотоники // Онтология проектирования. 2021. Т. 11, № 4(42). С. 422-436.

[2] Сафронов К.Р., Бессонов В.О., Федянин А.А. Оптимизация многослойных фотонных структур с помощью искусственных нейронных сетей для получения заданного оптического отклика // Письма в Журнал экспериментальной и теоретической физики. 2021. Т. 114, № 5-6(9). С. 360-364.

[3] Sutton R.S., Barto A.G. Reinforcement learning: An introduction. MIT press, 2018.

[4] Sutskever I., Vinyals, O., Le Q.V. Sequence to sequence learning with neural networks. In Advances in neural information processing systems, 2014, p. 3104-3112.

[5] Haykin S. Neural networks and learning machines (Vol. 3). Pearson, 2009.

[6] Jordan M.I., Mitchell T.M. Machine learning: Trends, perspectives, and prospects. Science, 2015, p. 255-260.

Estimation of Turkish Constitutional Court Decisions in Terms of Admissibility with NLP

Emrah Aydemir
Sakarya University, Sakarya Business School,
Division of Management Information Systems
Sakarya, Turkey
emrahaydemir@sakarya.edu.tr

***Abstract*— The widespread adoption of digitalization in the field of law has resulted in both faster processes and opportunities for artificial intelligence research. While there are now many artificial intelligence studies in the legal field, there are also cases where decisions are entirely made by artificial intelligence. In this study, the 6176th decision of the Constitutional Court in Turkey was collected from the official website and examined for acceptability. The decisions on "Events and Facts" header was separated out. These decisions were subjected to various preprocessing steps and vectorized using fasttext. In addition to the features obtained, the Claims of Remedy, Rights-Freedoms and Intervention in the file were also considered. All these attributes were taught to the machine using different classification algorithms with 10-fold cross validation. As a result, a successful classification rate of 84.82% was achieved. It is thought that this study will facilitate individual applications and reduce the workload of the court.**

Keywords— law; court decision; artificial intelligence

I. INTRODUCTION

The number of disputes that need to be resolved by judicial authorities is increasing day by day, and this situation is one of the biggest obstacles in accessing justice. As a result, as the duration of cases lengthens, parties become exhausted and lose confidence in the judiciary [1]. Particularly, it is expected that as the judiciary authorities rise, the number of disputes examined will be less. However, in Turkey, this is not considered to be entirely true for the Constitutional Court. Therefore, it can be said that in order to maintain the functionality of the highest judicial authority, the workload needs to be reduced. Of course, this court also has different workloads such as cancellations, objections, political party financial audits, and supreme court trials. But the main and heavy workload of this court consists of individual applications [2]. Between September 2012 and June 2022, there were 428,554 individual applications to the Constitutional Court and 320,253 of them were concluded. In the last year alone, 67,395 applications were made [3].

The aim of an individual application is to protect fundamental rights and freedoms that cannot be remedied through ordinary legal remedies [4]. Undoubtedly, the provision of individual application for the guarantee of fundamental rights and freedoms is valuable and necessary. However, it is important and necessary to improve the working conditions of the court in order to effectively resolve these applications. In this sense, the court needs to be restructured. Artificial intelligence systems can take on the most effective role in restructuring.

The first starting point in solving the workload problem is undoubtedly the admissibility criteria. In this sense, looking at countries with a long history of individual applications, it can be seen that admissibility criteria are the first resort in solving the workload problem [5]. These criteria filter out applications that do not fall within the scope of the court's work or do not meet the necessary rules and prevent them from moving on to the substantive examination stage. The most basic among these criteria can be counted as exhaustion of the application route, 30 days in the application, and clearly lacking a basis. In this respect, it could be argued that this filtering significantly reduces the workload, but it should not be forgotten that these processes also constitute a workload. The fact that individuals make individual applications directly to the court without any executive action or similar and that this right is used directly brings many deficiencies in the applications.

Individual applications are a secondary legal remedy, and solutions should first be sought within the general justice system for violated rights and freedoms [6]. Otherwise, the workload at higher authorities will further increase. However, the ways to be followed in the application to prevent or remedy the alleged violations of rights claimed by individuals differ for different events. Therefore, this examination can only be carried out by the Constitutional Court [7]. Hence, distinguishing between those that do not contain fundamental rights violation and those that do is a necessity at the outset [8]. The most effective method to try to reduce the workload that this examination will create may be to benefit from artificial intelligence systems.

II. FASTTEXT

Natural Language Processing (NLP) aims to enable computers to process, read, understand, and interpret human languages. It emerged for this purpose and covers artificial intelligence and linguistics. Of course, the most fundamental process in achieving this goal is the conversion of words or phrases into numerical values that the computer can process. Various methods have been proposed since the past for digitizing texts. However, statistical methods based on whether or not the words are present in the relevant documents or their frequencies have given way to probabilistic methods trained with artificial neural networks [9]. Although artificial neural networks perform well in tasks related to natural language processing, they also show some important issues. The most important of these is the time it takes to train the model. To solve this problem, in 2016, a company called Facebook produced a method called FastText to create word vectors. This open-source method's architecture is shown in Fig. 1 [10].

This work was supported by the Scientific and Technological Research Council of Turkey (TÜBİTAK) through the Scientific and Technological Research Projects Support Program (3005) with project number 122G019.

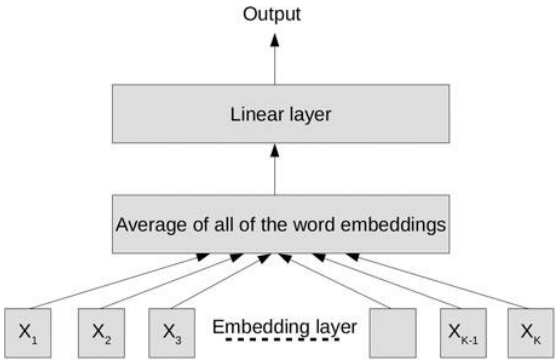

Fig. 1. Fasttext model

Compared to traditional bag-of-words methods, the fastText method also calculates n-gram features in addition to the word representation for each word input. This makes the word vectors more specific and provides better results for rare or unique words. The fastText method also includes two main components, CBOW (Continuous Bag of Words) and Skip-gram. CBOW allows predicting a given word using other words around it. On the other hand, Skip-gram uses a given word to predict other words around it. FastText can also be used for tasks such as classification. For this purpose, the common features of all examples belonging to a specific class are extracted, and these features are used in the model.

III. Material and Method

A. Dataset

The data provided by the Constitutional Court Decisions Information Bank [11] was used in the study. A total of 11,330 decisions were published, but not all of them have the "Case and Facts" title. 10,623 decisions contain the desired titles. The reasons for this situation include changes in the rules for publishing decisions from a formal perspective. In the decisions published over the past month, this title has been removed and merged with other titles. Decisions that involve infringement of rights and those that do not have been combined as "Acceptable". Therefore, the final distribution of the dataset is as given in the table below.

TABLE I. Distribution of Court Decisions

Label		Total	Percent	
Admissible	Violation of Rights	5713	53.77	60.37%
	No Violation of Rights	702	6.60	
Inadmissible		4208	39.61%	
Grand total		10623	100	

B. Preprocessing

When the decision texts were examined, it was found that some decisions had either very long or very short text lengths. Therefore, a total of 3,092 decisions with lengths below 2,000 characters, which did not correspond to at least one page, were removed first. Additionally, 580 decisions over 20,000 characters in length were also removed. In the end, a total of 6,950 decisions remained. After these operations, punctuation marks within each decision were removed since they do not carry any meaning. Also, frequently used and content-independent words in Turkish (such as "bir", "bu", "şu") were removed. These words, which are present in almost all documents, do not contribute positively to understanding the texts and negatively affect the results. Along with this, words that appear less than 10 times in all documents were also removed. These words consist of either misspelled words or extremely rare words. After the completion of the preprocessing process, the distribution of decisions is given in the table below.

TABLE II. Distribution of Final Court Decisions

Label	Number	Percent
Admissible	3862	55.56%
Inadmissible	3088	44.43%
Total	6950	100.00%

C. Feature Extraction and Classification

The fastText algorithm was used to convert decision texts into numerical values. This algorithm converted each decision text into a 931-dimensional vector. In addition to this, 24 types of rights and 39 types of remedies were added as features. Finally, 266 types of intervention were also added as attributes, which are thought to be effective in the results. The decision type was added as the final value to each of these vectors, and the feature matrix was extracted. These features were classified using five different algorithms:

- DecisionTreeClassifier
- QuadraticDiscriminantAnalysis
- RandomForestClassifier
- MLPClassifier
- GaussianNB

All operations and steps taken in the study were briefly summarized as follows.

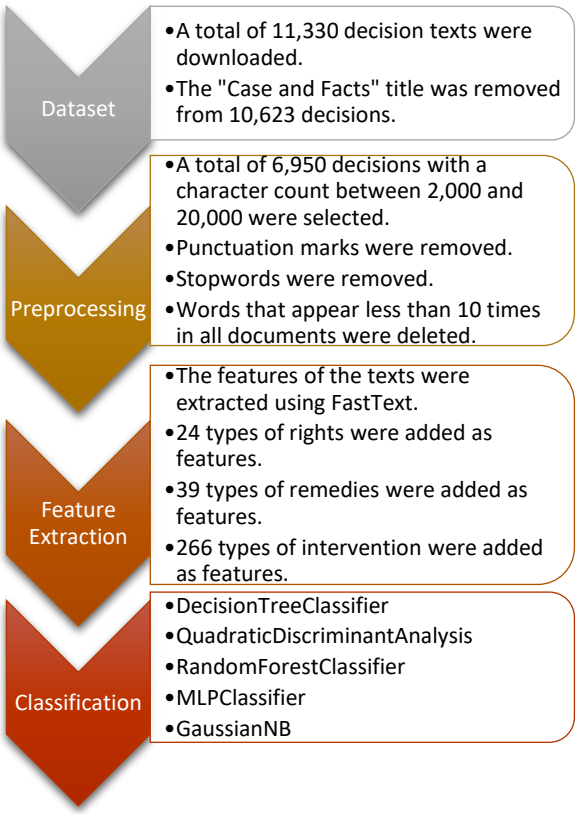

Fig. 2. Main stages of this methodology

IV. RESULTS

Python programming language was used for data analysis in the study. The data was divided into training and test data using 10-fold cross-validation method. Firstly, a feature file was created by combining the feature vectors. This file was tested with five different classification algorithms. Default values were used for the parameters of the classification algorithms. The results obtained for five different methods in classifying the features are given in the table below as accuracy, F1-Score, recall, and precision values. If you pay attention to the values in the table, the highest classification success of 88.90 % was achieved with the DecisionTreeClassifier method. The other four methods also showed good overall performance. The success criteria for each fold are given for the DecisionTreeClassifier method in the following figure.

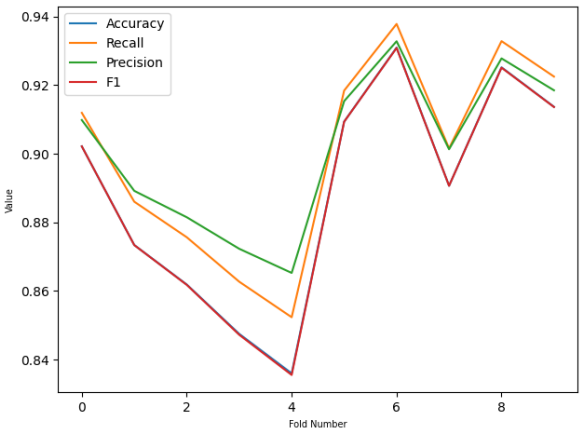

Fig. 3. Performance metrics for each fold of ten-fold cross-validation

TABLE III. SUCCESS CRITERIA FOR DIFFERENT CLASSIFIERS

Group Name	Method	Accuracy	F1	Recall	Precision
tree	DecisionTreeClassifier	0.8890	0.8889	0.9001	0.9013
discriminant_analysis	QuadraticDiscriminantAnalysis	0.8483	0.8411	0.8440	0.8602
ensemble	RandomForestClassifier	0.8417	0.8375	0.8349	0.8453
neural_network	MLPClassifier	0.8050	0.7826	0.8081	0.8559
naiveBayes	GaussianNB	0.8037	0.7943	0.7903	0.8177

The confusion matrix table for the DecisionTreeClassifier method, which achieved the highest success rate, is given in the following figure. When examining the table, it can be seen that inadmissible decisions are predicted with 100% success while admissible decisions are predicted with 80% success. As a result, only 771 out of 6950 decisions were misclassified.

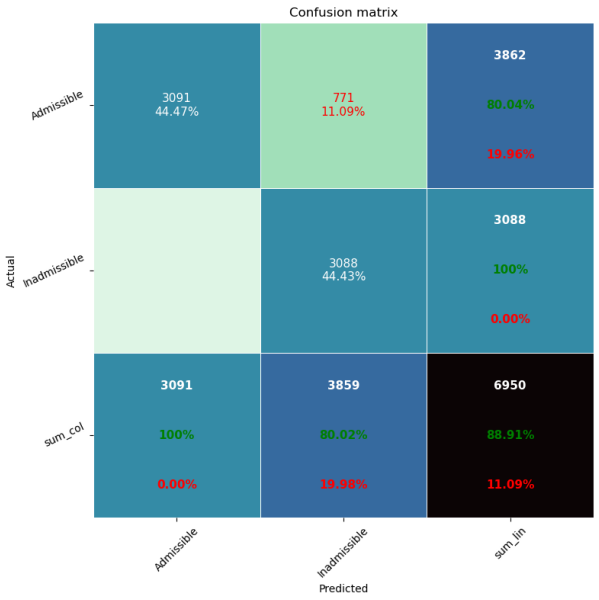

Fig. 4. Confusion matrix for DecisionTree method

V. CONCLUSION

This study aimed to determine the inadmissible or admissible status of individual applications at the pre-screening stage. An 88.90 % successful classification was achieved. Out of 11,330 decisions published by the Constitutional Court so far, 6,611 of them are inadmissible. Considering that 58.34 % of the decisions are inadmissible, it is thought that this study will make a significant contribution. The workload of the court will be reduced with this study and faster decisions can be made. There are also those who argue that predicting legal decisions from text is unsuccessful in explaining the "internal" perspective [12]. However, studies like modeling in texts are spreading in different areas every day [13–15]. Therefore, artificial intelligence studies from such texts are also seen in various ways in the field of law [16–18].

REFERENCES

[1] SODEV. "Yargı Bağımsızlığı ve Yargıya Güven Araştırma Raporu." Sosyal Demokrasi Vakfı. https://sodev.org.tr/yargi-bagimsizligi.pdf (accessed 29.03.2023.

[2] H. Ekinci, "Anayasa Mahkemesinin Bireysel Başvuru İş Yükü, Çözüme Yönelik Mahkeme Pratiği ve Öneriler," Uyuşmazlık Mahkemesi Dergisi, no. 5, pp. 391-432, 2015.

[3] AYM. "Bireysel Başvuru İstatistikleri (23 Eylül 2012 - 30 Haziran 2022)." Anayasa Mahkemesi. https://www.anayasa.gov.tr/tr/duyurular/bireysel-basvuru-istatistikleri-23-eylul-2012-30-haziran-2022/ (accessed 29.03.2023.

[4] B. KILINÇ, "Karşılaştırmalı Anayasa Yargısında Bireysel Başvuru Anayasa Şikayeti Kurumu ve Türkiye Açısından Uygulanabilirliği," Anayasa Yargısı, vol. 24, no. 1, pp. 17-57, 2008.

[5] İ. Demirci, "Bireysel Başvuruda Anayasal ve Kişisel Önem Kriteri ve Anayasa Mahkemesinin İş Yükü Sorunu Bağlamında İncelenmesi," Anayasa Yargısı, vol. 39, no. 2, pp. 355-393.

[6] H. Atasoy, "Türk Hukukunda Anayasa Mahkemesine bireysel başvurunun kabul edilebilirlik koşulları," 2014.

[7] H. Atasoy, "Türk Hukukunda Bireysel Başvuru Yolu," Türkiye Adalet, 2012.

[8] H. Ekinci, "Anayasa Mahkemesine Bireysel Başvuruda Kabul Edilebilirlik Kriterleri ve İnceleme Yöntemi," Anayasa Yargısı, vol. 29, no. 1, pp. 161-197, 2013.

[9] N. Chomsky, Syntactic structures. Mouton de Gruyter, 2002.

[10] A. Meghanani, C. Anoop, and A. G. Ramakrishnan, "Recognition of alzheimer's dementia from the transcriptions of spontaneous speech using fastText and cnn models," Frontiers in Computer Science, vol. 3, p. 624558, 2021.

[11] KBB. "Bireysel Başvuru Kararları." T.C. Anayasa Mahkemesi Kararlar Bilgi Bankası. https://kararlarbilgibankasi.anayasa.gov.tr/ (accessed 29.03.2023.

[12] H. L. A. Hart, H. L. A. Hart, J. Raz, and L. Green, The concept of law. oxford university press, 2012.

[13] K. M. Quinn, B. L. Monroe, M. Colaresi, M. H. Crespin, and D. R. Radev, "How to analyze political attention with minimal assumptions and costs," American Journal of Political Science, vol. 54, no. 1, pp. 209-228, 2010.

[14] M. A. Livermore, A. B. Riddell, and D. N. Rockmore, "The Supreme Court and the judicial genre," Ariz. L. Rev., vol. 59, p. 837, 2017.

[15] A. B. Riddell, "How to read 22,198 journal articles: Studying the history of German studies with topic models," Distant Readings: Topologies of German culture in the long nineteenth century, pp. 91-114, 2014.

[16] G. Leibon, M. Livermore, R. Harder, A. Riddell, and D. Rockmore, "Bending the law: geometric tools for quantifying influence in the multinetwork of legal opinions," Artificial Intelligence and Law, vol. 26, pp. 145-167, 2018.

[17] F. Dadgostari, M. Guim, P. A. Beling, M. A. Livermore, and D. N. Rockmore, "Modeling law search as prediction," Artificial Intelligence and Law, vol. 29, pp. 3-34, 2021.

[18] M. A. Hall and R. F. Wright, "Systematic content analysis of judicial opinions," Calif. L. Rev., vol. 96, p. 63, 2008.

Первые шаги к аппаратной реализации резервуарной вычислительной системы со спайковым выходным слоем на основе органических мемристоров

А. Н. Мацукатова[1,2], Н. В. Прудников[1,3], В. А. Кулагин[1,2], А. Д. Трофимов[1,3], А. В. Емельянов[1,3]

[1]*Национальный исследовательский центр «Курчатовский институт»*
[2]*Московский государственный университет имени М. В. Ломоносова*
[3]*Московский физико-технический институт (НИУ МФТИ)*
an.matcukatova@physics.msu.ru

***Аннотация*. Мемристоры – это элементы цепи, которые могут под действием электрических импульсов изменять свое сопротивление и сохранять его в течение длительного времени без внешнего воздействия, что делает их многообещающими кандидатами на роль синапсов в нейронных сетях. На данный момент большое количество научных групп по всему миру работает над аппаратной реализацией нейронных сетей с их помощью. При этом одним из главных препятствий становится вариативность мемристивных характеристик. Частично решить возникающую проблему позволяют новые архитектуры нейронных сетей: резервуарные вычислительные системы, спайковые нейронные сети. В данной работе предлагается создание мемристивной резервуарной вычислительной системы со спайковым выходным слоем. Первая часть работы посвящена тестированию органических мемристоров на основе полианилина и поли-*n*-ксилилена на роль синапсов в резервуарном и считывающем слое системы соответственно. Органические мемристоры перспективны из-за малой стоимости, простоты синтеза и возможности изготовления на гибких подложках. Вторая часть работы посвящена сравнению спайкового выходного слоя системы со стандартным формальным слоем. Показано, что при использовании спайкового выходного слоя резервуарная вычислительная система демонстрирует повышенную устойчивость к вариативности мемристивных характеристик.**

Ключевые слова: резервуарные вычисления; спайковые нейронные сети; мемристоры

I. Обзор литературы

Несмотря на стремительное развитие нейронных сетей и их успешное применение в различных областях, программно реализованные нейронные сети сталкиваются с ограничениями, свойственными традиционной компьютерной архитектуре фон Неймана [1]. Важной задачей становится аппаратная реализация нейронных сетей, например, на базе новых перспективных элементов – мемристоров [1]. Мемристоры могут под действием электрических импульсов изменять свое сопротивление и сохранять его в течение длительного времени без внешнего воздействия, что делает их многообещающими кандидатами на роль синапсов в нейронных сетях. На данный момент уже продемонстрированы многослойные полносвязные и сверточные сети на основе мемристоров [1]. Аппаратная реализация формальных нейронных сетей сталкивается с множеством проблем, важнейшая из которых заключается в стохастичности, присущей мемристивным характеристикам. Так как формальные нейронные сети чаще всего обучаются с помощью энергоемкого алгоритма градиентного спуска, и все веса нейронной сети изменяются на каждом обучающем шаге, мемристивная стохастичность может значительно влиять на точность нейронной сети в целом. Для частичного решения возникающей проблемы было предложено несколько подходов, например, использование спайковых нейронных сетей (СНС) [2] или резервуарных вычислительных систем (РВС) [3]. Обсудим каждый из подходов.

СНС кодируют и обрабатывают информацию с помощью относительного времени прихода импульсов (спайков). Обновление веса в таких сетях происходит только при перекрытии спайков, поэтому СНС более энергоэффективны, чем традиционные формальные нейронные сети. СНС можно обучать по биоподобному алгоритму пластичности, зависящей от времени прихода спайков (spike-timing-dependent plasticity, STDP) [4]. Кроме этого СНС более устойчивы к стохастичности мемристивных характеристик [4].

РВС состоят из двух основных частей: резервуарного и считывающего (выходного) слоя. Резервуарный слой нелинейным образом обрабатывает входной сигнал и извлекает из него признаки, важные для дальнейшей классификации данных с помощью считывающего слоя. При этом обучение и изменение весов происходит только в считывающем слое, который может представлять собой простую полносвязную сеть, что значительно упрощает процедуру обучения. Уже были продемонстрированы программные и аппаратные РВС на основе мемристоров [5], но обучение считывающего слоя в таких системах по-прежнему реализуется с помощью алгоритма градиентного спуска.

В этой работе предлагается объединить два подхода и создать РВС со спайковым считывающим слоем на базе органических мемристивных структур. Органические мемристоры не уступают неорганическим по своим основным характеристикам, при этом они обладают неоспоримыми преимуществами, их можно дешево и достаточно просто производить, они биологически совместимы, могут быть созданы на гибких подложках

Работа выполнена при финансовой поддержке РФФИ, проект № 20-57-7801

[6]. Для РВС необходимо два типа мемристоров: для резервуара были выбраны мемристоры на основе полианилина (ПАНИ) с кратковременной памятью, а для считывающего слоя мемристоры на основе поли-*n*-ксилилена (ППК) с долговременной памятью.

II. Экспериментальная часть

Мемристоры на основе ПАНИ были изготовлены методом Ленгмюра-Шефера [7]. Мемристоры на основе ППК с внедренными наночастицами MoO_3 синтезировались методом низкотемпературной газофазной полимеризации на поверхности [8].

Для моделирования СНС использовалась библиотека BindsNET. На основе вольт-амперных характеристик и STDP была построена мемристивная модель – Voltage ThrEshold Adaptive Model, которая затем использовалась в СНС. Для моделирования формальной нейронной сети (ФНС) использовалась библиотека Pytorch и экспериментальные кривые потенциации/депрессии. В модель СНС (для единообразия и в ФНС тоже) были введены дополнительные входы с инвертированным сигналом для выравнивания интенсивности различных изображений. Значительным отличием модели ФНС от СНС стала необходимость использования двух мемристоров на один вес ФНС (для реализации отрицательных весов). Подробное описание представлено в работе [9].

III. Основные результаты

A. *Поставленная задача*

Была поставлена задача классификации бинаризованных изображений паттернов и цифр. На входы резервуара изображения подавались построчно в виде 3-битных последовательностей импульсов (рис. 1). После каждого изображения на входы резервуара подавались импульсы чтения. Токи полученные на импульсах чтения затем использовались как входные данные для модели считывающего слоя РВС. Считывающий слой представлял собой полносвязную СНС, основанную на экспериментальных характеристиках ППК мемристоров, и обучался по биоподобному алгоритму STDP. Для сравнения также был смоделирован формальный считывающий слой, обучающийся по алгоритму градиентного спуска.

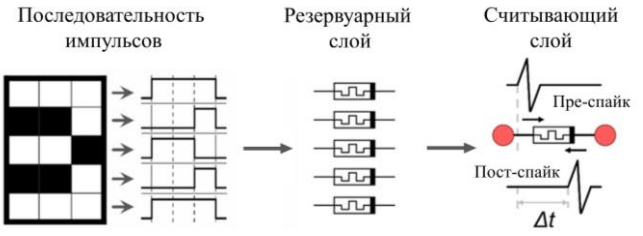

Рис. 1. Кодирование изображения цифры последовательностями импульсов, которые подаются на резервуарный слой, состоящий из пяти ПАНИ мемристоров. Затем получившиеся токи подаются на считывающий слой, смоделированный на основе характеристик ППК мемристоров

B. *Резервуарный слой на основе полианилиновых мемристоров*

Итак, на резервуарный слой, состоявший из ПАНИ мемристоров, подавались 3-битные строки: белый пиксель подавался в виде импульса 0.9 В, а черный в виде импульса 0.3 В длительностью 50 мс. После закодированного таким образом изображения на каждый ПАНИ мемристор подавался импульс чтения амплитудой 0.4 В. После импульса чтения следовал длительный отрицательный импульс (-0.3 В, 1000 мс) для приведения всех ПАНИ мемристоров обратно в исходное состояние.

Каждая из 8 возможных последовательностей (от «000» до «111») подавалась на ПАНИ мемристоры суммарно 100 раз в случайном порядке. Ответом на каждую последовательность являлось единственное значение тока, полученное на импульсе чтения. Видно, что токи, полученные после разных последовательностей, различимы и достаточно слабо пересекаются (рис. 2). Таким образом, можно сказать, что ПАНИ мемристоры успешно извлекают важные признаки, необходимые для дальнейшей классификации поступающих на входы изображений.

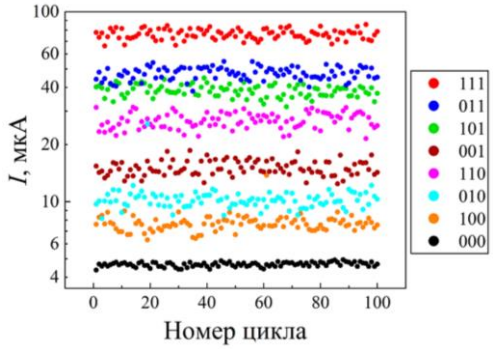

Рис. 2. Значения тока, снятые в случайном порядке для каждой из восьми возможных последовательностей битов; измерено по 100 циклов для каждой последовательности

C. *Мемристоры на основе поли-n-ксилилена для считывающего слоя*

Мемристоры на основе ППК демонстрировали долговременную память, то есть их резистивное состояние оставалось стабильным в течение длительного времени. На рис. 3*а* показано 36 стабильных резистивных состояний данных мемристивных структур.

Важным условием использования ППК мемристоров в считывающем слое была возможность изменения их резистивного состояния по биоподобному алгоритму STDP для обучения нейронной сети. Полученная зависимость (рис. 3*б*) похожа на зависимости, получаемые в биологических системах. Проводимость увеличивается, если постсинаптический спайк приходит на мемристор позже пресинаптического, что соответствует положительному Δt на рис. 3*б*. Можно сказать, что если постсинаптические нейроны генерируют импульс непосредственно после пресинаптических, то между ними имеет место причинно-следственная связь. Такую связь необходимо усилить, увеличение проводимости соответствует увеличению синаптического веса в биологических структурах. И наоборот, проводимость уменьшается, если постсинаптический спайк приходит на мемристор раньше пресинаптического, что свидетельствует о нарушении причинно-следственной связи. В обоих случаях меньшая разница во времени прихода спайков приводит к большему изменению проводимости. Рис. 3*б* демонстрирует возможность настройки отклика мемристивной структуры с помощью изменения амплитуды используемых спайков.

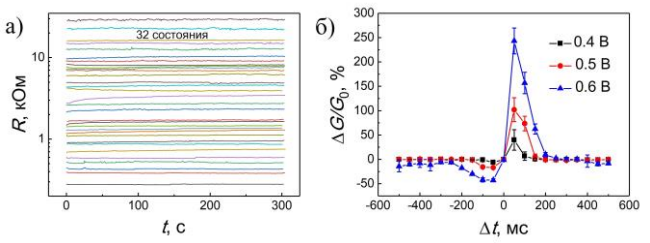

Рис. 3. а) Демонстрация возможности многоуровневого резистивного переключения мемристивных структур на основе ППК. б) Пример изменения проводимости ППК мемристора по алгоритму STDP из одинакового первоначального состояния G_0 = 1 мСм, но с разными амплитудами спайков. Каждая точка кривой STDP – медиана по 10 экспериментам

D. Моделирование считывающего слоя

Итак, токи, полученные после аппаратного резервуарного слоя, подавались на смоделированный считывающий слой СНС или ФНС с внедренными мемристивными характеристиками ППК структур. Таким образом, решались 2 задачи: классификация паттернов 3x3 (рис. 4*а*) и классификация цифр 5x3 (рис. 4*б*). В каждую модель считывающего слоя внедрялся экспериментальный разброс мемристивных характеристик: для СНС коэффициент вариации (КВ) составлял 61 %, для ФНС – 5.6 %. По рис. 4*в* видно, что ФНС справляется с первой задачей лучше, чем СНС, хотя после 200 эпох обучения точность обеих сетей превышает 95 %. Если же использовать КВ равный 61 % для ФНС (то есть уравнять КВ ФНС и СНС), результаты классификации значительно ухудшаются, что указывает на неустойчивость ФНС к более высокому разбросу мемристивных характеристик.

Для второй задачи точность классификации, полученная с помощью ФНС снова оказалась выше, чем для СНС (рис. 4*г*). Увеличение КВ ФНС в данном случае приводит к невозможности обучения ФНС. Более того, повышение сложности задачи увеличивает разброс точности ФНС, в то время как разброс точности СНС не зависит от задачи (сравнивая рис. 4*в* и 4*г*). Причина большей устойчивости СНС к разбросу характеристик мемристоров заключается в локальном характере правил обучения: в отличие от ФНС на каждом шаге обучения важно направление изменения веса, но не его точное количественное изменение.

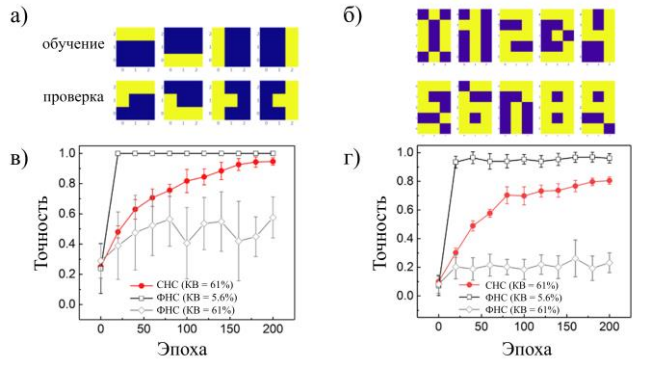

Рис. 4. а) Изображения, используемые для задачи классификации паттернов и б) задачи классификации цифр. в), г) Точность классификации паттернов и цифр с помощью СНС и ФНС, КВ уточнен на графике

IV. Заключение

В данной работе предложена резервуарная вычислительная система на основе двух типов органических мемристивных устройств. Аппаратно реализованный резервуар на основе ПАНИ мемристоров смог выделить важные признаки из входных данных. ППК мемристоры продемонстрировали все необходимые характеристики для создания считывающего слоя на их основе. Считывающий слой СНС устойчив к вариациям мемристивных характеристик, в то время как такие же вариации приводят к значительному ухудшению точности ФНС. Более того, увеличение архитектуры считывающего слоя приводит к увеличению разброса точности ФНС и не влияет на разброс точности СНС. Полученные результаты демонстрируют возможность успешного и эффективного использования органических мемристоров для аппаратной реализации резервуарных вычислительных систем со спайковым выходным слоем.

Благодарность

Измерения выполнены с использованием оборудования ресурсных центров НИЦ «Курчатовский институт». Авторы благодарны А.А. Ступникову за синтез ПАНИ пленок и А.А. Несмелову за синтез нанокомпозитного ППК.

Список литературы

[1] Zhang Y., Wang Z., Zhu J., Yang Y., Rao M., Song W., Zhuo Y., Zhang X., Cui M., Shen L., Huang R., Joshua Yang J. Brain-inspired computing with memristors: Challenges in devices, circuits, and systems // Appl. Phys. Rev. 2020. Vol. 7, № 1. P. 011308, doi: 10.1063/1.5124027.

[2] Prezioso M., Mahmoodi M.R., Bayat F.M., Nili H., Kim H., Vincent A., Strukov D.B. Spike-timing-dependent plasticity learning of coincidence detection with passively integrated memristive circuits // Nat. Commun. Springer US, 2018. Vol. 9, № 1. P. 5311, doi: 10.1038/s41467-018-07757-y.

[3] Park J., Kim T.-H., Kwon O., Ismail M., Mahata C., Kim Y., Kim S., Kim S. Implementation of convolutional neural network and 8-bit reservoir computing in CMOS compatible VRRAM // Nano Energy. 2022. Vol. 104. P. 107886, doi: 10.1016/j.nanoen.2022.107886.

[4] Querlioz D., Bichler O., Dollfus P., Gamrat C. Immunity to Device Variations in a Spiking Neural Network With Memristive Nanodevices // IEEE Trans. Nanotechnol. 2013. Vol. 12, № 3. P. 288–295, doi: 10.1109/TNANO.2013.2250995.

[5] Milano G., Pedretti G., Montano K., Ricci S., Hashemkhani S., Boarino L., Ielmini D., Ricciardi C. In materia reservoir computing with a fully memristive architecture based on self-organizing nanowire networks // Nat. Mater. Springer US, 2022. Vol. 21, № 2. P. 195–202, doi: 10.1038/s41563-021-01099-9.

[6] van de Burgt Y., Melianas A., Keene S.T., Malliaras G., Salleo A. Organic electronics for neuromorphic computing // Nat. Electron. 2018. Vol. 1, № 7. P. 386–397, doi: 10.1038/s41928-018-0103-3.

[7] Lapkin D.A., Emelyanov A.V., Demin V.A., Erokhin V.V., Feigin L.A., Kashkarov P.K., Kovalchuk M.V. Polyaniline-based memristive microdevice with high switching rate and endurance // Appl. Phys. Lett. 2018. Vol. 112, № 4. P. 043302, doi: 10.1063/1.5013929.

[8] Matsukatova A.N., Vdovichenko A.Y., Patsaev T.D., Forsh P.A., Kashkarov P.K., Demin V.A., Emelyanov A. V. Scalable nanocomposite parylene-based memristors: Multifilamentary resistive switching and neuromorphic applications // Nano Res. 2023. Vol. 16, № 2. P. 3207–3214, doi: 10.1007/s12274-022-5027-6.

[9] Matsukatova A.N., Prudnikov N. V, Kulagin V.A., Battistoni S., Minnekhanov A.A., Trofimov A.D., Nesmelov A.A., Zavyalov S.A., Malakhova Y.N., Parmeggiani M., Ballesio A., Marasso S.L., Chvalun S.N., Demin V.A., Emelyanov A. V, Erokhin V. Combination of Organic-Based Reservoir Computing and Spiking Neuromorphic Systems for a Robust and Efficient Pattern Classification // Adv. Intell. Syst. 2023. P. 2200407, doi: 10.1002/aisy.202200407.

Оценка нейросетевого алгоритма повышения точности обработки сигналов с вращающегося трансформатора

Е. Ю. Антонова, Ю. А. Жуков
БГТУ «ВОЕНМЕХ» им. Д.Ф. Устинова
E-mail kantonowa@yandex.ru, zh_kv@mail.ru

***Аннотация*. В настоящее время разработано множество подходов к созданию прецизионных датчиков угла на основе обработки данных вращающихся трансформаторов. Ключевой проблемой при этом является построение алгоритмов, повышающих точность обработки на основе модели преобразования. В настоящей работе предлагается перспективный подход на основе нейросети прямого распространения для повышения точности обработки сигналов с аналого-цифрового преобразователя напряжений вращающегося трансформатора (сокр. АЦПВТ). Для оценки нейросетевого алгоритма разработана модель АЦПВТ, на основе которой сформирована обучающая выборка. Разработана структура и обучена нейросеть в пакете программ Matlab Simulink. Представлены структура нейросети, результаты моделирования, оценки точности алгоритма обработки данных АЦПВТ. Даны рекомендации по применению нейросетевого подхода для обработки данных нейросети, обсуждаются пути развития в направлении исследований.**

Ключевые слова: вращающийся трансформатор, точность преобразования, искусственная нейронная сеть

I. Введение

В мехатронных и робототехнических системах широко применяются датчики углового положения. Одним из наиболее распространенных датчиков положения является СКВТ – синусно-косинусный вращающийся трансформатор или резольвер.

Вращающийся трансформатор представляет собой четырехобмоточную электрическую машину с индукционным взаимодействием роторных и статорных обмоток. На первичную обмотку подается высокочастотное синусоидальное напряжение. В зависимости от перемещения вала двигателя со вторичных обмоток поступают два аналоговых сигнала, сдвинутые друг относительно друга на 90π. Эти сигналы преобразуются в сигнал для использования в управлении двигателем с помощью различных методов модуляции [1].

К достоинствам вращающихся трансформаторов можно отнести высокую стабильность работы, механическую прочность, устойчивость в переходных процессах. Отсутствие встроенной электроники позволяет использовать датчики в условиях повышенной радиации. К недостаткам можно отнести невысокую точность по сравнению с оптическими энкодерами и индуктосинами. Источниками ошибок во вращающемся трансформаторе являются рассогласование амплитуд и фазовый сдвиг питающих напряжений, неидеальная квадратура, влияние высших гармоник питающих напряжений и выходных потокосцеплений.

Повышение точности вращающегося трансформатора можно достигнуть путем введения новых схемотехнических решений и улучшения алгоритмической части программного обеспечения. В настоящее время известно множество разработок, направленных на повышение точности вращающихся трансформаторов. Так, в работе [2] предлагается определение угла вращающегося трансформатора при помощи аналогового преобразователя, позволяющего точно определять угол без участия процессора и таблицы поиска («look-up table», сокр. «LUT»). Основная идея такого преобразователя заключается в получении N числа синусоид с фазовым сдвигом из сигналов с датчика с последующим мультиплексированием и получением выходного сигнала. В статье [3] авторами предыдущей разработки предлагается преобразователь, основанный на разнице между абсолютными значениями сигналов датчика вместе с простой формирующей сетью на основе сигнальных диодов. И, наконец, в источнике [4] авторами предложена упрощенная схема системы преобразователя сигнала вращающегося трансформатора на основе фазовой автоподстройки частоты (сокр. ФАПЧ). Предлагаемый преобразователь работает без использования генератора, управляемого напряжением (сокр. ГУН), цифро-аналогового преобразователя (сокр. ЦАП), счетчика и таблиц поиска. Метод основан на схеме извлечения, которая использует опорные сигналы переменного тока для определения синуса/косинуса расчетного угла.

В источниках [5–6] Сарма и др. рассматривают использование цифрового сигнального процессора (англ. «digital signal processor», сокр. «DSP») для определения положения и скорости, а также обнаружения неисправностей, определения систематических ошибок и избавления от паразитных гармоник в сигнале, получаемом с вращающегося трансформатора.

Ванг и др. в статье [7] анализирует работы предыдущих авторов и указывает на неустойчивость предложенных методов [5–6] к загрязнению шумами за счет использования одной пары данных, предлагая взамен выборку выходных данных с датчика с более высокой частотой дискретизации и вычисление углового

Работа выполнена в соответствии с Дополнительным соглашением от 09.06.2020 № 075-03-2020-045/2 между Минобрнауки и БГТУ «ВОЕНМЕХ» им. Д.Ф. Устинова на выполнение государственного задания по теме «Разработка фундаментальных основ создания и управления группировками высокоскоростных беспилотных аппаратов космического и воздушного базирования и группами робототехнических комплексов наземного базирования» (шифр «Роботы – 2024»).

значения с несколькими парами данных (метод, так называемых, «избыточных выборок»).

В источнике [8] авторами предлагается схемотехническое решение 16-битного преобразователя сигналов вращающегося трансформатора, устойчивого к радиационному излучению, со следующими значениями по точности: статическое угловое разрешение 16 бит (4,2 угловых секунды) и разрешение 10 бит (6 угловых минут) при частоте вращения ротора 100 оборотов в секунду.

В работе [9] описан преобразователь сигналов вращающегося трансформатора в виде системы с обратной связью, точность которой регулируется пропорционально-интегрально-дифференциальным регулятором (ПИД-регулятором) для оценки скорости и положения ротора двигателя.

В статье [10] рассмотрено уменьшение погрешностей получаемых с датчика сигналов за счет измерения данных при помощи искусственной нейронной сети (сокр. ИНС), состоящей из трех входных слоев, десяти нейронов в скрытом слое и двух выходных слоев. В качестве устройства обработки данных была выбрана программируемая логическая интегральная схема (сокр. ПЛИС).

Несмотря на множество представленных подходов, задача обработки данных вращающегося трансформатора не потеряла свою актуальность. В последнее время все более активно внедряются методы, основанные на инструментах теории искусственного интеллекта. В настоящей работе предлагается применение искусственной нейронной сети прямого распространения для повышения точности обработки сигналов с вращающегося трансформатора. В ходе работы поставлены задачи формирования модели обработки сигналов вращающегося трансформатора, на основании которой готовится обучающая выборка, выбора структуры нейросети и синтеза её параметров. По результатам обучения оценивается качество обработки данных предложенного алгоритма.

II. Модель обработки данных АЦПВТ

A. *Принцип работы вращающегося трансформатора*

Модель обработки данных вращающегося трансформатора формируется на основе уравнений электрического равновесия первичных и вторичных обмоток с учетом погрешностей, влияющих на преобразование сигналов.

На рис. 1 приведена схема бесщеточного вращающегося трансформатора со статорным кольцевым трансформатором (англ. «ring transformer», сокр. «RT»), за счет которого происходит возбуждение ротора. Рассмотрим систему уравнений, описывающих физические процессы во вращающемся трансформаторе.

Кольцевой трансформатор на статоре запитывается переменным напряжением с частотой Ω_e и фазой φ_e:

$$V_{RT} = V_{RTm}\sin(\Omega_e t + \varphi_e) \quad (1)$$

Ток трансформатора – I_{sRT}. Ток ротора можно записать в следующем виде:

$$I_{rRT} = I_{rRTm}\sin(\Omega_e t) \quad (2)$$

Поскольку вращающийся трансформатор является двухфазной машиной, можно записать систему уравнений в соответствии с выражениями (1) и (2) для физических процессов, происходящих в обмотках статора с учетом перехода к преобразованию Лапласа (s-оператору):

$$\begin{cases} V_1 = RI_1 + LsI_1 + s[(L_m\cos(p_{res}\Theta_{me}))I_{rRT}] \\ V_2 = RI_2 + LsI_2 + s[(L_m\sin(p_{res}\Theta_{me}))I_{rRT}] \end{cases} \quad (3)$$

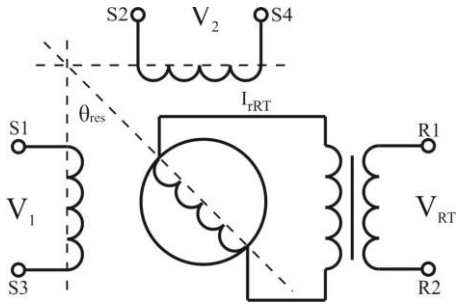

Рис. 1. Схема бесщеточного вращающегося трансформатора [11]

Или, с учетом взятия производной по переменным угла Θ_{me} и тока I_{rRT}:

$$\begin{cases} V_1 = RI_1 + LsI_1 - L_m I_{rRT} p_{res}\Omega_{me}\, sin(p_{res}\,\Theta_{me}) \\ \quad +L_m\, cos(p_{res}\,\Theta_{me})(sI_{rRT}) \\ V_2 = RI_2 + LsI_2 + L_m I_{rRT} p_{res}\Omega_{me}\, cos(p_{res}\,\Theta_{me}) \\ \quad +L_m\, sin(p_{res}\,\Theta_{me})(sI_{rRT}) \end{cases} \quad (4)$$

где: Ω_{me} – угловая скорость; Θ_{me} – механический угол; p_{res} – число пар полюсов; V_1, V_2 – напряжения вторичных обмоток; I_1, I_2 – токи вторичных обмоток; R – сопротивление вторичных обмоток; L – индуктивность вторичных обмоток; L_m – взаимная индуктивности первичной и вторичных обмоток.

В состоянии холостого хода в обмотках статора не будет тока, и производные тока будут равны нулю ($I_1 = I_2 = sI_1 = sI_2 = 0$). В случае синхронной выборки обоих напряжений V_1 и V_2, при условии, что $\sin\Omega_e t = 0$ и $\cos\Omega_e t = 1$, ток $I_{rRT} = 0$, производная достигает максимума: $sI_{rRT} = I_{rRTm}\Omega_e\cos\Omega_e t = I_{rRTm}\Omega_e$. Тогда в соответствии с формулами (3) и (4):

$$\begin{cases} V_1 = L_m\cos(p_{res}\,\Theta_{me})I_{rRTm}\Omega_e \\ V_2 = L_m\sin(p_{res}\,\Theta_{me})I_{rRTm}\Omega_e \end{cases} \quad (5)$$

Из уравнений получаем, что механический угол $\Theta_{me} = \Theta_{res}/p_{res}$. Угол может быть рассчитан с использованием стандартных программных решений [11].

B. *Влияние высших гармоник на точность измеряемого угла*

При проектировании реального устройства сложно добиться идеальных выходных сигналов в форме синуса и косинуса. Обычно в сигнале будут содержаться дополнительные гармоники более высоких порядков, зависящие от угла поворота ротора. Тогда, если выделить отдельно функции угла после преобразования, уравнения (5) можно переписать следующим образом:

$$\begin{cases} V_1 = \sin(p_{res}\,\Theta_{me}) + \sum_{n=2}^{\infty} k_n \sin(np_{res}\Theta_{me}) \\ V_2 = \cos(p_{res}\,\Theta_{me}) + \sum_{n=2}^{\infty} k_n \cos(np_{res}\Theta_{me}) \end{cases} \quad (6)$$

где k_n – коэффициент при n-й гармонике.

Записав оценку углового положения $\widehat{\Theta}$ в уравнение рассогласования по фазе $\varepsilon = V_1 cos(p_{res}\widehat{\Theta}) - V_2 sin(p_{res}\widehat{\Theta})$ в следящем контуре с астатизмом 2-го порядка, подставляя в уравнение (6) и обозначив ошибку по углу $\widetilde{\Theta} = \Theta - \widehat{\Theta}$, получим ее зависимость от высших гармоник [12]:

$$\widetilde{\Theta} \approx -\sum_{n=2}^{\infty} k_n \sin(n-1)p_{res}\Theta_{me}$$

III. Нейросетевой алгоритм обработки данных АЦПВТ

Предлагаемый нейросетевой алгоритм обработки данных АЦПВТ основан на аппроксимации входных напряжений искусственной нейронной сетью прямого распространения (англ. «Feedforward neural network»), в которой сигнал распространяется строго от входного слоя к выходному. На рис. 2 представлена схема предлагаемого алгоритма обработки сигнала. На вход нейросети подаются сигналы с синусной и косинусной обмоток резольвера, прошедшие демодуляцию. Сеть фильтрует поступившие на вход контроллера сигналы. На выходе ИНС генерируются обработанные сигналы синуса и косинуса, из которых затем можно получить угол любым расчетным методом. В качестве источника ошибки выбраны 3-я и 5-я гармоники.

На рис. 3 представлена структура предлагаемой нейронной сети. Сеть состоит из двух входных слоев, двух выходных слоев и двух скрытых слоев, каждый из которых состоит из десяти нейронов. Для слоев выбраны следующие функции активации: для входного слоя - линейная функция (purelin function), для скрытых слоев и выходного слоя – сигмоидальная функция (sigmoid function). При моделировании было установлено, что меньшее число нейронов дает худший результат при обучении. Также в процессе моделирования было установлено, что сигмоида – функция активации нейронов скрытого слоя, дающая наиболее качественный результат при обучении.

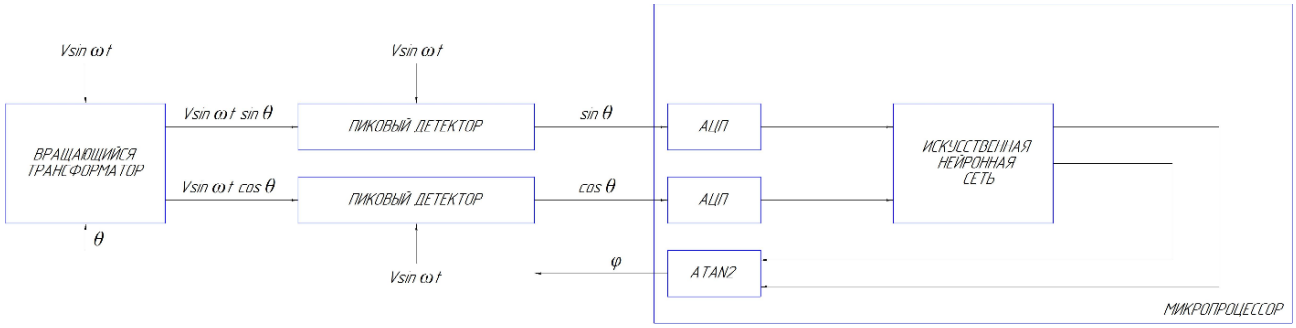

Рис. 2. Схема предлагаемого алгоритма обработки сигнала

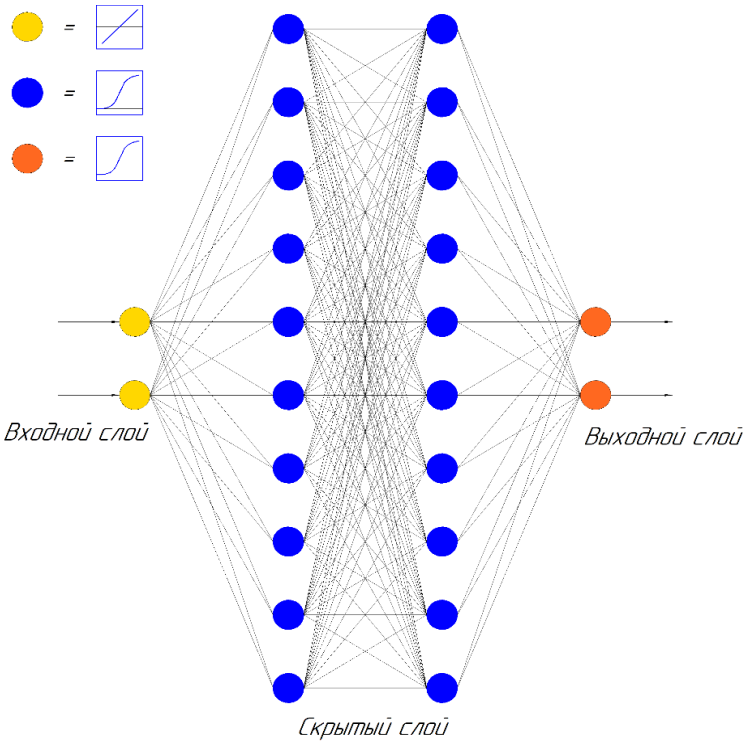

Рис. 3. Структура предлагаемой нейронной сети

IV. Моделирование и оценка точности алгоритма обработки данных АЦПВТ

Для проектирования нейросети был использован пакет программ Matlab Simulink: в коде программы была задана архитектура сети и выполнено обучение, затем была сгенерирована сеть и дополнена в Simulink сигналами высших гармоник в соответствии с (6). Полученная модель представлена на рис. 4. На рис. 5 представлен график ошибки обучения нейросети. На рис. 6 приведены графики восстановленного сигнала исходного механического угла, угла без применения фильтра и с применением ИНС-фильтра.

При разработке модели учитывались следующие допущения: сигналы получены с АЦП и прошли демодуляцию, на вход системы подается ступенчатое изменение электрического угла, на выходе восстанавливается механический угол. Число пар полюсов равно 16 и выбрано в соответствии с паспортными данными вращающегося трансформатора 2,5БВТ-Д ЛШ3.010.518-10.

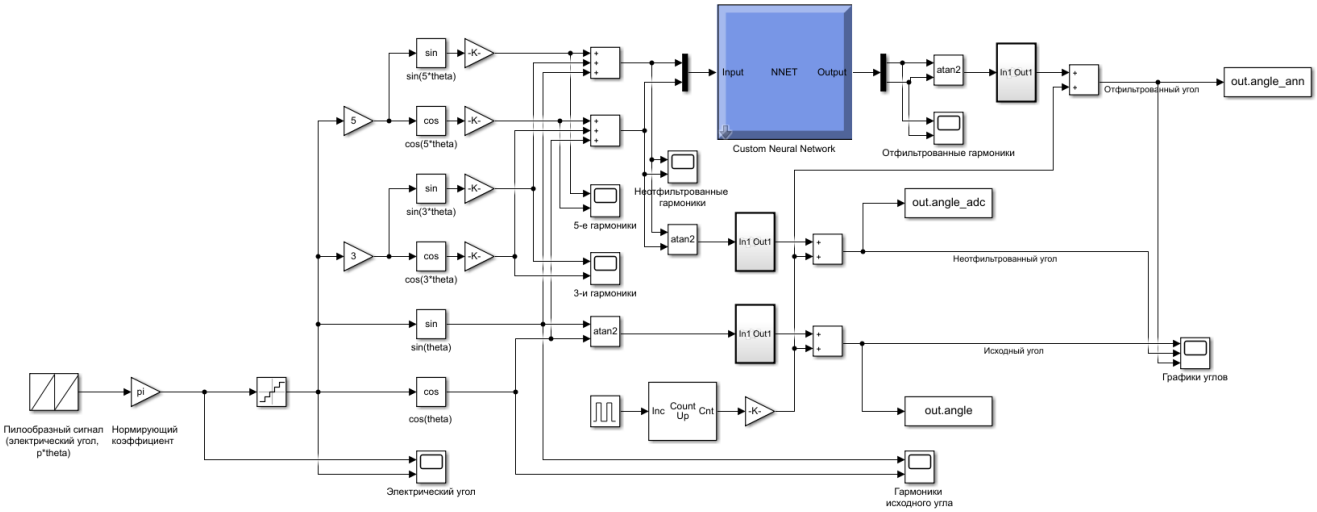

Рис. 4. Схема модели в Simulink

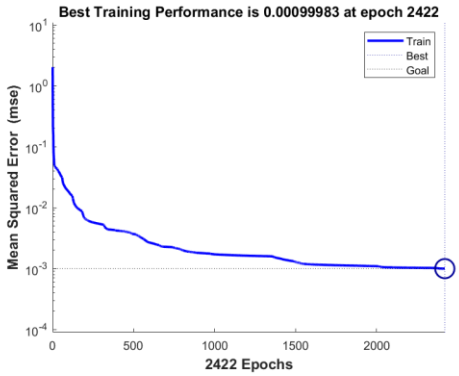

Рис. 5. График ошибки обучения нейросети

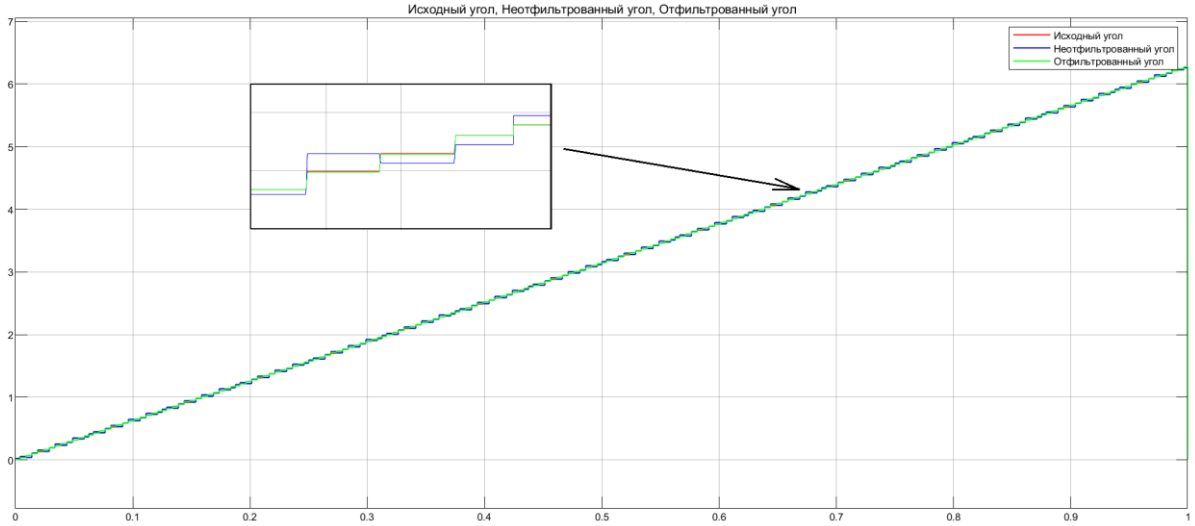

Рис. 6. Графики углов: исходный угол, угол без применения фильтра и угол после прохождения ИНС-фильтра

В табл. 1 приведена оценка точности без использования фильтра и с ИНС-фильтром в системе: максимальная (max) и среднеквадратическая ошибки (mse) рассогласования угла. Видно, после применения ИНС ошибки уменьшились.

ТАБЛИЦА I. ОЦЕНКА ТОЧНОСТИ

Ошибка рассогласования угла	max	mse
Без фильтра	0.0307	4.7e−4
С ИНС-фильтром	0.0109	1.1e−5

V. ЗАКЛЮЧЕНИЕ

В результате работы получена оценка точности алгоритма обработки данных АЦПВТ на основе искусственной нейронной сети. Получено, что после прохождения нейросетевого фильтра ошибка оценки угла снижается. Однако, для реализации на основе контроллеров общего назначения требуется оценка производительности и быстродействия предложенного алгоритма. Также стоит провести сравнение качества фильтрации сети прямого распространения с другими видами нейронных сетей, например, рекуррентной нейронной сетью.

СПИСОК ЛИТЕРАТУРЫ

[1] Воротников С.А. Информационные устройства робототехнических систем: учеб. пособие. М. : Изд-во МГТУ им. Н.Э. Баумана, 2005. 384 с.

[2] Benammar M., Ben-Brahim L., Alhamadi M.A., Al-Naemi M. A novel method for estimating the angle from analog co-sinusoidal quadrature signals. Sensors Actuators A Phys. 2008;142:225–231. doi: 10.1016/j.sna.2007.02.025.

[3] M. Benammar, M. Bagher and M. Al Kaisi, "Digitally-tuned resolver converter", Proc. Chem., vol. 1, pp. 449-452, 2009.

[4] Al-Emadi, Nasser & Ben-Brahim, L. & Benammar, Mohieddine. (2014). A new tracking technique for mechanical angle measurement. Measurement. 54. 58–64. 10.1016/j.measurement.2014.04.011.

[5] Sarma, Santanu & Agrawal, V.K. & Udupa, Subramanya & Parameswaran, K.. (2008). Instantaneous angular position and speed measurement using a DSP based resolver-to-digital converter. Measurement. 41. 788-796. 10.1016/j.measurement.2007.11.010.

[6] Sarma, Santanu & Venkateswaralu, A.. (2009). Systematic error cancellations and fault detection of resolver angular sensors using a DSP based system. Mechatronics. 19. 1303-1312. 10.1016/j.mechatronics.2009.09.002.

[7] Wang, Jianming & Zhu, Ming & Ding, Ling. (2012). Noise-robust software based R/D conversion methods using over-sample technique. Computers & Electrical Engineering. 38. 1636–1646. 10.1016/j.compeleceng.2012.06.012.

[8] Leroux, Paul & Koeckhoven, Wesley & Verbeeck, Jens & Uffelen, Marco & Esque, Salvador & Ranz, Roberto & Damiani, Carlo & Hamilton, David. (2014). Design of a MGy radiation tolerant resolver-to-digital convertor IC for remotely operated maintenance in harsh environments. Fusion Engineering and Design. 89. 10.1016/j.fusengdes.2014.03.066.

[9] Li, Yaoling & Wu, Zhong. (2018). High-accuracy resolver-to-digital conversion via phase locked loop based on PID controller. IOP Conference Series: Materials Science and Engineering. 339. 012003. 10.1088/1757-899X/339/1/012003.

[10] Celikel, Resat. (2019). ANN based angle tracking technique for shaft resolver. Measurement. 148. 10.1016/j.measurement.2019.106910.

[11] Балковой А.П., Цацекин В.К. Прецизионный электропривод с вентильными двигателями. М.: Изд-воМЭИ, 2010. 328 с.

[12] Wang, Rui & Wu, Zhong & Shi, Yongli. (2021). Suppressing Harmonics in Resolver Signals via FLL Based Complementary Filters. IEEE Access. PP. 1-1. 10.1109/ACCESS.2021.3130921.

Применение нейросетевых технологий в системах мониторинга и диагностики газовых турбин большой мощности

П. В. Соколов, В. С. Карелин
Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» им. В.И. Ульянова (Ленина)
pvsokolov@etu.ru, karelinvld@gmail.com

Аннотация. **Работа посвящена применению нейросетевых технологий в системах мониторинга и диагностики газовых турбин. Проанализированы основные особенности и проблемы этого подхода. Исследованы существующие решения для выявления неисправностей энергетического оборудования. Описан подход с использованием физики процессов в оборудовании, с применением методов машинного обучения, в частности нейросетевых технологий. Приведены основные проблемы, возникающие при данном решении.**

Ключевые слова: нейронные сети, машинное обучение, газотурбинные установки, мониторинг, диагностика

I. Введение

Штатные системы диагностики и АСУ ТП не дают возможность глубоко анализировать показатели работы оборудования и выявлять неисправности на ранних стадиях. Современные Автоматизированные системы мониторинга и предиктивной диагностики (далее – АСМПД) позволяют решить эту задачу. В настоящей статье пойдёт речь об АСМПД для энергетического оборудования, такого как газовые турбины. Основная идея заключается в определении подходов и принципов диагностики оборудования.

В настоящее время на рынке АСМПД для энергетического оборудования представлено достаточно большое количество систем. Зачастую такие системы используют принцип регрессионного анализа. Некоторые системы обладают достаточно надёжным математическим аппаратом, который позволяет прогнозировать значения параметров работы оборудования в будущем. Однако, такие системы не могут достоверно интерпретировать причину возникновения того или иного отклонения и выдать рекомендации по нормализации параметра без привлечения экспертов, которые хорошо разбираются в особенностях конструкции и эксплуатации того или иного оборудования. Помимо этого, в рамках диагностики газового оборудования, в существующих АСМПД не уделяется достаточного внимания таким важным неисправностям как вибрационное состояния лопаток.

II. Существующие решения для мониторинга и диагностики энергетического оборудования

Разработке систем предиктивной диагностики уделяется большое внимание в таких крупных энергомашиностроительных корпорациях, как General Electric, Siemens. Разработкой подобных систем также занимаются производители систем автоматизации: Emerson, Schneider Electric. Среди отечественных производителей можно выделить НПО ЦКТИ (Видас, Ментор) и Ротек (ПРАНА).

В качестве основного примера будет рассмотрена система производства АО «Ротек» – ПРАНА.

Система ПРАНА (ПР – прогнозная, АНА – аналитика) – система прогностики и удаленного мониторинга для ведения непрерывного контроля, осуществления диагностики и прогнозирования изменения технического состояния энергетического оборудования, разработанная специалистами АО РОТЕК[1].

Данная система определена двумя уровнями – нижним и верхним. Нижний уровень обеспечивает агрегацию данных с АСУ ТП, а также их предварительную обработку и передачу в сторону верхнего уровня. В основу нижнего уровня входят эксплуатационные параметры, полученные от первичных преобразователей и датчиков, установленных на оборудовании.

Верхний уровень представляет собой экспертно-диагностический центр, куда могут поступать данные с разнообразных объектов. В нем происходит аналитическая обработка данных и их визуализация.

В основу системы заложен алгоритм, базирующийся на построении модели работы по статистическим данным. В режиме реального времени происходит сравнение текущего состояния агрегата с моделью. В системе ПРАНА для реализации моделей энергетического оборудования используется частный вариант семейства методов SBM – метод MSET (Multivariate State Estimation Technique). Оценка отличия вектора аргументов от рассчитываемого по методу MSET модельного в этом методе производится по критерию Хотеллинга T^2. Влияние отдельных аргументов на отклонение от модели в случае нарушения критерия T^2 оценивается с помощью расчета разлаженности по методу MSET. Моделирование производится в режиме онлайн. Метод MSET используется также в режиме офлайн как дополнительное средство анализа.[1]

Основная идея данного подхода заключается в создании эталонной модели оборудования на основании полученных исторических данных. В соответствии с этим, первым этапом для работы системы является разметка данных и определение нормальных режимов эксплуатации для получения эталонной модели.

Далее определяется обучающая матрица состояний. В результате мы получаем эталонную модель, которую необходимо сравнить с фактическими измеренными параметрами, а также рассчитать значения невязки и среднеквадратичного отклонения. Конечным параметром для определения является интегральная величина – критерий T^2.

Критерий T^2 – критерий, предназначенный для проверки гипотезы H_0, согласно которой истинное значение вектора $\mu = (\mu_1, ..., \mu_p)$ математических ожиданий невырожденного p-мерного нормального закона $N(\mu, B)$, ковариационная матрица которого тоже неизвестна, есть вектор $\mu_0 = (\mu_{1_0}, ..., \mu_{p_0})$ [2].

При изменении зависимостей измеренных значений значение этой величины существенно возрастает. Таким образом, эталонная модель представляет собой вектор-функцию от вектора аргументов параметров. Анализ T^2-критерия позволяет прогнозировать изменения в техническом состоянии оборудования и выявлять ранее неизвестные зависимости параметров[1].

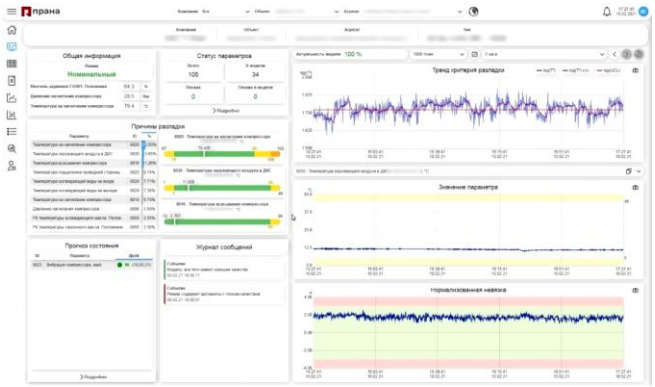

Рис. 1. Пример интерфейса системы предиктивной аналитики ПРАНА АО «РОТЕК»

III. Применение нейросетевых технологий на базе построения физических моделей энергетического оборудования

A. Общее описание системы

АСМПД газовых турбин предназначена для обеспечения достоверной оценки текущего состояния и прогнозирования изменения технологических параметров газовой турбины, минимизации числа внеплановых простоев и ремонтов, предотвращения развития аварийных процессов, сокращения времени поиска и устранения неисправностей, планирования состава и объема ремонтного ЗИП.

В ходе работы системы диагностики выполняются следующие принципиальные шаги:

- в реальном времени принимаются показания КИП оборудования;
- на основе диагностических эталонных моделей вычисляются значения контролируемых параметров;
- вычисляются разладки между контролируемыми параметрами из эксплуатации и их значениями по расчету моделей, на основе полученных разладок определяется интегральный показатель технического состояния подсистемы;
- в случае, когда показатель технического состояния становится ниже заданного предела, автоматический классификатор дефектов выбирает неисправность, характерную для данного сочетания разладок контролируемых параметров;
- выполняется прогноз показателя технического состояния для заданных горизонтов прогнозирования;
- выполняется оценка остаточного ресурса.

Таким образом, базовым элементом системы являются конфигурируемые эталонные модели.

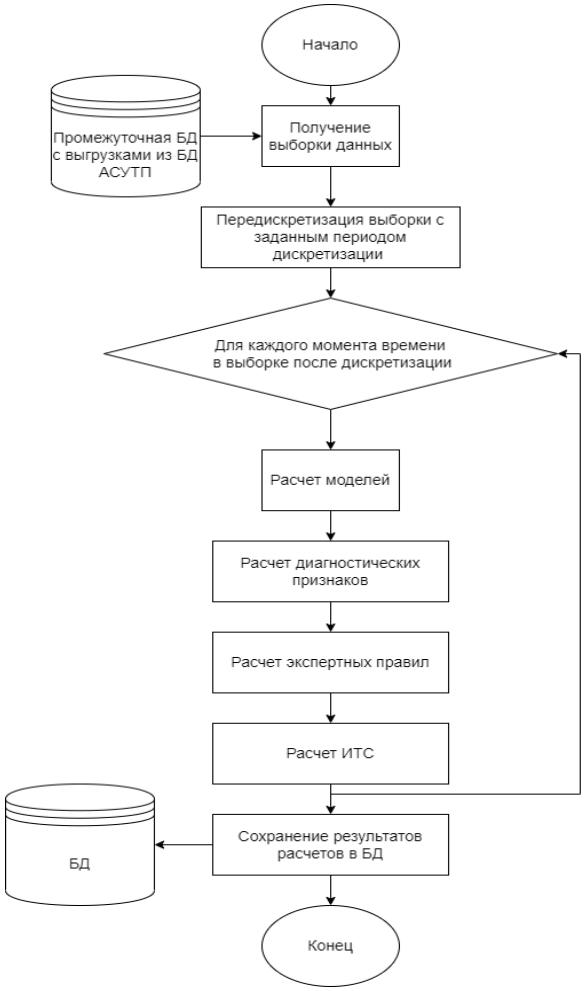

Рис. 2. Блок-схема работы АСМПД

На основании эталонных моделей подсистем ГТУ система должна реализовывать алгоритмы диагностики в виде следующих принципиальных модулей:

- модуль приема и обработки технологических величин;
- модуль расчета эталонных моделей;
- модуль определения обобщающих интегральных показателей, реализующий расчет индекса технического состояния;
- модуль идентификации неисправностей;
- модуль прогноза технического состояния;
- модуль прогноза остаточного ресурса.

Далее приведена блок-схема работы АСМПД.

B. Общая информация об эталонных моделях

Эталонная математическая модель является отображением множества входных параметров во множество выходных параметров:

$$f = X \to Y \quad (1)$$

В процессе работы системы рассчитываются значения одних технологических параметров (выходные параметры) на основе значений других технологических параметров (входные параметры) в дискретные моменты времени:

$$Y(t_i) = f(X(t_i)) \quad (2)$$

Расчет основывается на предположении, что подсистема, для которой используется математическая модель, исправна

Если дефект в установке не развивается, то разладка между расчетными и фактическими значениями технологических параметров не будет превышать собственную ошибку математической модели.

При развитии дефекта фактические значения технологических параметров и значения, рассчитанные при помощи эталонной математической модели, будут отличаться – возникает разладка.

Для *j*-го выходного параметра в *i*-й момент времени разладка определяется следующим образом:

$$\delta y_j(t_i) = y_j(t_i) - \hat{y}_j(t_i) \quad (3)$$

$y_j(t_i)$ – фактическое значение *j*-го технологического параметра, полученного от АСУТП газовой турбины, в момент t_i;

$\hat{y}_j(t_i)$ – фактическое значение *j*-го технологического параметра, полученного от АСУТП газовой турбины, в момент t_i.

Как правило, величина разладки пропорциональна степени развития дефекта. Следовательно, для предотвращения крайней степени развития дефекта необходимо сигнализировать о превышении разладки некоторого предельного значения $max(\delta y)$. Сигнализация осуществляется при помощи диагностических признаков.

Диагностический признак – это логическая функция, принимает на вход ряд расчетных параметров и выдает логическую переменную, принимающую значение «Истина» или «Ложь» в зависимости от заданного выражения. Далее на базе диагностического признака или группы диагностических признаков в работу применяется экспертное правило.

Экспертное правило – это логическая функция, получающая на вход значения булевого типа от диагностических правил и на основе заданного логического выражения выдающая переменную булевого типа в зависимости от того, обнаружен дефект или нет. Пример экспертного правила приведен на рис. 3.

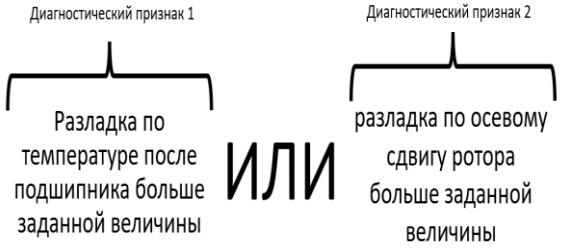

Рис. 3. Пример экспертного правила

C. Описание подходов к разработке моделей

Разработка эталонной математической модели для некоторой подсистемы включает в себя несколько этапов:

- определение архитектуры математической модели (входные и выходные параметры);
- выбор данных для обучения математической модели;
- выбор рациональной архитектуры нейронной сети для математической модели;
- обучение математической модели с выбранной рациональной архитектурой нейронной сети и оценка её точности.

При определении архитектуры математической модели сначала формируется набор выходных параметров. Выходные параметры выбираются исходя из того, какой дефект можно выявить при помощи диагностических признаков, где будет использован данный выходной параметр. При этом руководствуются научно-технической литературой о газовой турбине, а также экспертными знаниями специалистов организации-производителя. Кроме того, данные технологические параметры должны собираться системой АСУТП.

Набор входных параметров выбирается либо на основе корреляционного анализа данных, либо на основе анализа рабочих процессов подсистемы турбоагрегата.

Рабочие процессы внутри моделируемой подсистемы оборудования могут быть смоделированы на основе связанных физико-математических моделей из разных областей, например, механика деформируемого твердого тела и механика жидкости и газов.

Зачастую взаимосвязь между выходными и входными параметрами является достаточно сложной для явного задания в виде систем уравнений, но данную взаимосвязь можно аппроксимировать, если есть данные по входным и выходным параметрам при различных режимах работы оборудования.

Следовательно, представленные математические модели по типу своему являются суррогатными моделями на основе архитектуры полносвязной нейронной сети. Полносвязные нейронные сети являются универсальными аппроксиматорами, а теоретическая возможность нейронной сети аппроксимировать почти любую функцию подтверждается теоремой Колмогорова–Арнольда[3]. Работа Колмогорова была адаптирована Хехт–Нильсеном для нейронных сетей (НС) в [4].

Пример архитектуры полносвязной нейронной сети представлен на рис. 4.

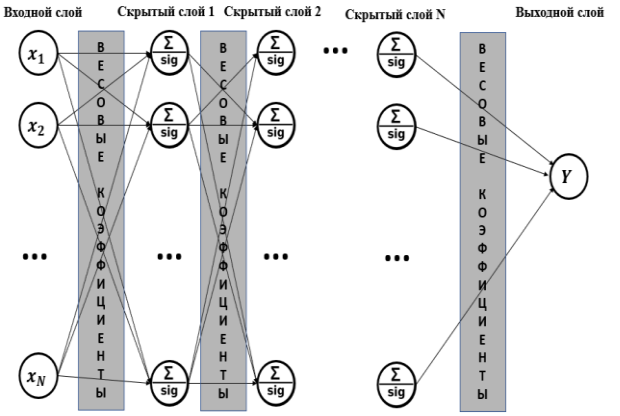

Рис. 4. Пример архитектуры полносвязной нейронной сети (многослойный перцептрон)

Значения весовых коэффициентов определяются в процессе обучения на выборке данных входных и выходных параметров математической модели.

- данные для обучения должны быть собраны в период нормальной эксплуатации, так как эталонная модель должна описывать поведение моделируемой подсистемы в штатном состоянии;
- в данных для обучения НС диапазоны изменения входных и выходных параметров математической модели должны соответствовать таковым при использовании НС в процессе работы для расчета штатных значений выходных параметров;
- удельное соотношение различных режимов эксплуатации должно быть примерно одинаковым;
- данные для обучения должны быть собраны в период, когда работа моделируемой подсистемы является установившейся.

Выбор рациональной архитектуры нейронной сети для математической модели заключается в выборе гиперпараметров нейронной сети, чтобы получить минимальную погрешность математической модели по результатам процедуры k-кратной перекрестной проверки.

Как правило, чем сложнее связь между входными и выходными параметрами, тем больше требуется скрытых слоёв с большим количеством нейронов. Диапазоны вариации гиперпараметров задаются исходя из конфигурации математической модели.

Рациональные значения гиперпараметров для каждой модели определяются путем решения задачи оптимизации: подобрать такие значения гиперпараметров из заданного пространства поиска, чтобы функция потерь, рассчитываемая по k-кратной перекрестной проверке, была минимальна.

С точки зрения практического применения полносвязной нейронной сети в качестве основного решения выше поставленной задачи для автоматизированных систем мониторинга и предиктивной диагностики газовых турбин можно выделить следующие основные преимущества решения:

- устойчива к переобучению;
- хорошо выявляет физические взаимосвязи;
- хорошо обучается на данных низкого качества (высокий уровень шума, выбросы, пропуски).

В результате анализа основных технологических величин газовых турбин был определен ряд диагностируемых неисправностей.

В первую очередь большой интерес представляет камера сгорания и её переход в режим виброгорения. Для получения аномалий и их дальнейшей классификации требуется контролировать как общие параметра: обороты ротора, температура воздуха на входе и т. д., так и конкретные для данного узла: перепад давления в камере сгорания, пульсации давления в камере сгорания.

Также можно отметить такую важную неисправность как повышенный нагрев вкладыша подшипника. Для этой неисправности контролировать необходимо общие параметры, а также температуру вкладыша подшипника.

IV. Заключение

В данной статье были описаны существующие автоматизированные системы диагностики энергетического оборудования. Также был приведен альтернативный подход к реализации системы на базе нейросетевых технологий для газовых турбин. Ключевое отличие данного варианта заключается в наличии классификатора дефектов, который по определенным правилам должен производить определение выявленных аномалий в автоматическом режиме.

На основании предложенной методики допускается определение существующих проблем для данных систем.

- В части развития необходима организация хранения архивов измеряемых технологических параметров.
- Необходимо увеличение существующего КИП для улучшения классификатора дефектов.
- Основную проблему в описанном подходе представляет неоднородность данных.

В соответствии с определенными проблемами будут сформированы вопросы, ответы на которые станут основой для построения будущей автоматизированной системы мониторинга и предиктивной диагностики газового оборудования.

Список литературы

[1] Опыт использования удаленного доступа и предсказательной аналитики состояния энергетического оборудования / С.А. Наумов, А.В. Крымский, М.А. Липатов, Д.Н. Скрабатун // Теплоэнергетика. 2018. №4 с. 21-33.

[2] Виноградов И.М.Математическая энциклопедия. М.: Советская энциклопедия. 1977–1985.

[3] Колмогоров А.Н. О представлении непрерывных функций нескольких переменных в виде суперпозиций непрерывных функций одного переменного и сложения // Доклады Академии наук. Российская академия наук. 1957. Т. 114. №. 5. С. 953-956.

[4] Hecht-Nielsen R. Kolmogorov’s mapping neural network existence theorem //Proceedings of the international conference on Neural Networks. New York, NY, USA : IEEE Press, 1987. Т. 3. С. 11-14.

Сравнительный анализ методов обнаружения аномальных режимов работы турбогенератора

П. В. Соколов, И. В. Попов
Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» им. В.И. Ульянова (Ленина)
pvsokolov@etu.ru, popov_iv1@power-m.ru

***Аннотация*. Работа посвящена построению оптимальной системы диагностики турбогенераторов с целью обнаружения аномалий во временных рядах данных, а также способам классификации выявленных аномалий по группам. Проведен краткий обзор наиболее вероятных нестандартных режимов работы турбогенератора. Предложено использование технологий машинного обучения на основе уже полученных статистических данных. Рассмотрены особенности реализации цифровых моделей искусственных нейронных сетей в рамках задачи предиктивного выявления аномальных режимов работы оборудования. Сделаны выводы об эффективности исследованных методов.**

Ключевые слова: турбогенератор; аномальный режим работы; машинное обучение; нейронные сети

I. Введение

Вопрос надежной эксплуатации турбогенераторов на электростанциях является одним из определяющих факторов развития энергетики. С риском возможности выхода из строя оборудования растет и риск материальных затрат на внеплановые ремонты. При этом могут значительно увеличиться удельные капитальные вложения. Системы локальной диагностики оборудования – это хороший инструмент для сокращения таких рисков, количества поломок и выходов из строя турбогенератора. Одним из важных вопросов является диагностика режимов отличных от номинального и не соответствующих ГОСТ 533-2000 [1]. Такие режимы являются перегрузочными или аномальными режимами работы турбогенератора и представляют опасность, связанную с возможностью возникновения аварийной ситуации и выхода из строя всей установки. Это предъявляет большое количество требований к конструкторским решениям, к комплексу мер защиты турбогенератора.

Сложность диагностики этих режимов в том, что необходимо не только выявить аномальные режимы работы, но и заблаговременно предупреждать о появлении признаков перехода в такой режим.

В этом случае система должна представлять совокупность методов локальной диагностики, представляющих собой алгоритмы диагностирования входных величин, и методов, основанных на машинном обучении. Нейронные сети могут обучаться на статистических рядах временных данных собранных как в нормальных режимах работы, так и в аномальных. Эти модели могут быть использованы при поиске аномалий в данных, поступающих с системы локальной диагностики в режиме реального времени.

Используя данный подход, нам необходимо решить следующие задачи:

- подготовка данных для обучения, на данном этапе необходимо отфильтровать данные соответствующие выбросам от аномальных данных;
- поиск аномалий;
- классификация аномалий.

Первая задача решается путем фильтрации данных в алгоритмах локальной диагностики, где отсеиваются данные о выходе датчиков за диапазоны измерения, недостоверности значений, короткие замыкания в измерительной цепи и других неисправностях. В рамках второй задачи необходимо определить наиболее подходящий метод классификации данных по отношению к причине возникновения аномального режима.

II. Этап предварительной обработки исходных данных

На этапе подготовки данных для обучения задачу фильтрации выбросов можно решить с помощью системы локальной диагностики. По отношению к турбогенератору, временной ряд – это последовательность значений входных величин, упорядоченных в хронологическом порядке и представляющих собой характеристику этой величины. Поиск аномалий в таких временных рядах делится на два основных направления: детектирование выбросов и обнаружение новизны. Суть детектирования выбросов состоит в том, чтобы исключить из общего набора аномальных значений, те, которые появляются в результате выхода значения датчиков за диапазоны измерения, неточности измерения и других шумов. Ряды данных, полученные с работающего объекта, содержат выбросы и представляют собой набор необработанных данных, которые подлежат фильтрации по диагностическим признакам. Существующая архитектура системы диагностики в совокупности с системой прогнозирования состояния турбогенератора рассмотрена в статье [2]. Но для решения вышеуказанных задач предлагается переработанная схема архитектуры системы диагностики, представленная на рис. 1. На рис. 1 используются следующие обозначения:

- СИ – сервис интеграции, выполняющий роль преобразования исходных данных в нужный формат для предварительной подготовки данных;

- ИАД – источник архивных данных для обучения модели;
- ДРВ – данные реального времени, которые приходят с измерительных приборов при работе агрегата (в нашем случае используем источник данных, имитирующих работу ДРВ);
- СПО – система предварительной обработки данных, фильтрации выбросов;
- М – обученная модель на статистических данных;
- ОА – результат определения аномалий.

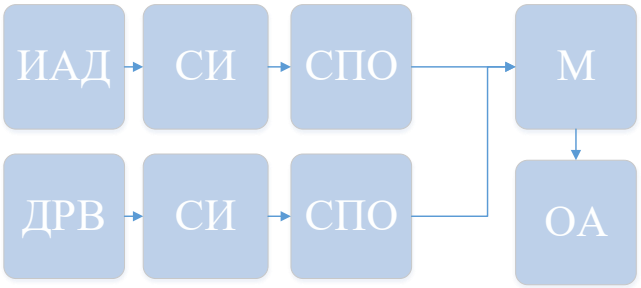

Рис. 1. Архитектура системы диагностики

В данной системе все входные величины проходят предварительную обработку, в которой необходимо определять отклонения параметров от нормы в соответствии с картой уставок, определенной экспертами в данной области на основе теоретических данных и опыта практического применения.

При необходимости, также определяемой экспертами в данной области, у величин, участвующих в алгоритмах системы диагностики, есть возможность выставить фильтрацию по входному значению, с помощью фильтра Калмана [3].

Следующие признаки должны быть определены при подготовке данных:

- короткое замыкание или обрыв измерительных цепей;
- выход из диапазона допустимых значений;
- неисправность измерительного прибора;
- отсутствие связи с измерительным прибором;
- сработка верхней и нижней аварийной уставки;
- сработка максимально возможного отклонения от номинальной величины.

В результате фильтрации данных с помощью алгоритмов диагностики оборудования, входными данными для задачи обнаружения новизны являются уже предварительно обработанные данные.

III. Наиболее вероятные аномальные режимы работы турбогенератора

При поиске аномалий необходимо учитывать причину возникновения аномалий. Поэтому аномальные режимы работы разделяют на несколько типов в зависимости от причин их возникновения. Ниже представлены наиболее вероятные причины возникновения аномалий.

A. Аварийные перегрузки по току

Аварийные перегрузки по току статора или ротора могут быть вызваны внешними короткими замыканиями, выпадением машины в асинхронный режим и другими причинами. Большую опасность в таком случае составляет повышение температуры в обмотках генератора вследствие повышения токов статора и ротора вплоть до механических повреждений. Чем больше кратность токов и продолжительность перегрузки, тем больше риск возникновения аварийной ситуации. Допускаются только кратковременные перегрузки по току, причем длительность их зависит от системы охлаждения генератора. Машины с непосредственным охлаждением обмоток более чувствительны к деформации обмоток при их нагревании, поэтому они допускают меньшие перегрузки, чем машины с косвенным охлаждением.

B. Потеря возбуждения, асинхронный режим

Турбогенератор переходит в асинхронный режим работы при потере возбуждения ли уменьшении возбуждения до критической величины. В современных мощных турбогенераторах переход в асинхронный режим может сопровождаться его отключением или сокращения уровня нагрузки до 60–70 % номинальной мощности. Поэтому особое внимание нужно уделить способам автоматического выявления и прогнозирования перехода в этот режим. Синхронный электромагнитный момент вызван совокупностью вращающихся магнитных потоков статора и ротора, обусловленного протеканием в обмотках ротора тока возбуждения. Так как последний момент является тормозным по отношению к вращению турбины, то при исчезновении тока возбуждения частота вращения ротора увеличивается, при этом возникает скольжение ротора по отношению к вращающемуся полю статора. Вследствие этого во всех контурах ротора со стороны статора наводятся токи, имеющие частоту скольжения. Если максимум момента турбины окажется меньше асинхронного момента этих токов, то генератор будет отдавать в сеть активную мощность при работе в асинхронном режиме. При этом турбогенератор может выйти в синхронный режим без внешних воздействий, если характеристика асинхронного момента, развиваемая при скольжении M(s) жесткая или крутая, где максимум характеристики больше значения момента турбины. Тогда при небольших величинах скольжения моменты уравновесятся, и генератор сохранит нагрузку. Останов же энергоблока может произойти если максимум M(s), будет значительно меньше момента вращения турбины $M_т$. В этом случае равновесие не установится, а частота вращения может возрасти до уставки срабатывания противоаварийной защиты турбогенератора [4].

C. Витковые замыкания в роторе

Витковые замыкания в обмотке ротора, как правило, возникают вследствие смещения ее при изменении температуры, при этом может произойти перекрытие каналов охлаждения, что усугубит ситуацию. На обмотку ротора большое влияние оказывают частицы металла, ржавчины или влаги. Замыкание обмотки ротора на корпус или землю само по себе не представляет опасности для машин и не приводит к отказу. Однако при наличии второго замыкания часть

обмотки ротора оказывается короткозамкнутой, что может вызвать прохождение через тело ротора больших токов и вследствие магнитной асимметрии большую вибрацию, которая приведет к аварийному отключению. Турбогенераторы в большинстве случаем могут продолжать работу некоторое время без значимых повреждений, поэтому на них устанавливается защита от двойных замыканий на землю, а при одиночных замыканиях генераторы продолжают работу.

D. *Режим работы генератора в несимметричных условиях, КЗ в электрической цепи*

Длительная несимметрия *токов* электрической цепи может быть вызвана обрывом одного из проводов, большой однофазной нагрузкой металлургических печей или электрической тяги, вследствие этого токи, протекающие в обмотках статора турбогенератора, так же оказываются несимметричными. Эти несимметричные токи наводят эллиптическое поле, эквивалентное двум вращающимся полям обратной и прямой последовательности. В этом случае токи в обмотках статора могут быть представлены в виде суммы токов этих полей. Причем составляющая поля обратной последовательности, вращающаяся с двойной частотой, наводит в роторных контурах токи частотой 100Гц. Такие токи создают дополнительный нагрев в соответствующих частях ротора, таких как клин, зуб, бандаж. Поэтому в первую очередь растет температура поверхностей, принадлежащих торцевой контактной зоне [4], что способствует их оплавлению. Таким образом, главным ограничивающим фактором использования турбогенератора в несимметричном режиме является опасность сильного нагрева элементов ротора. Несимметрия токов так же создает знакопеременный момент, который оказывает механическое воздействие на элементы генератора и может вызывать вибрацию отдельных элементов и механические напряжения. Но, исходя из конструкции турбогенераторов, цилиндр имеет большую толщину стали по отношению к малым диаметрам, этот фактор ограничивает передачу вибрации и радиальных усилий к креплениям сердечника к корпусу. Механическое воздействие при длительной несимметрии в пределах, допустимых по условиям нагрева бочки ротора несущественно, если несимметрия не имеет большую степень воздействия. Большая степень воздействия может возникать при непосредственной близости короткого замыкания к турбогенератору [4].

E. *Искажение синусоидального тока статора*

Существенная часть нагрузки энергосистем использует преобразователи из переменного в постоянный ток. Часть потребителей применяют устройства, преобразующие частоту 50 Гц в другие частоты. Эти преобразования неразрывно связаны с генерацией в сеть высших гармонических частот. При этом в обмотки статора генераторов проникают токи всех гармоник кроме третей и кратных третей гармонике частот. Они значительно искажают синусоидальную форму тока статора. Высшие гармонические частоты вызывают рост потерь в обмотке и активной стали статора. Кроме того, можно наблюдать появление в зазоре несинхронных магнитных полей, которые перемещаются относительно ротора турбогенератора. При этом поля разных гармоник могут вращаться как в прямой, так и в обратной последовательностях. Высокочастотные токи, вызываемые этими полями, протекают в верхних слоях массивных частей ротора и вызывают местные нагревы на его торцах. Такой режим работы турбогенератора может потребовать уменьшения нагрузки в сети.

IV. Поиск аномалий

A. *Постановка эксперимента*

Отфильтрованные статистические данные являются показаниями при работе турбогенератора в нормальном режиме, таким образом, мы можем обучить нейронную модель на основе этих данных, причем отклонение от показаний величин при работе в нормальном режиме будет идентифицироваться как аномалия. Критерием качества в такой системе примем функцию абсолютной ошибки. Абсолютная ошибка растет, когда данные отклоняются от нормальных значений, рассчитанных на этапе обучения модели.

Входными параметрами для анализа выбраны параметры с различным типом измеряемого сигнала:

- мощность ТГ (P);
- температура масла на смазку подшипников(T);
- осевая составляющая виброскорости подшипника(W).

Для анализа необходимо использовать временной период, в котором содержаться данные об останове турбогенератора.

B. *Обучение модели*

Обучение модели производилось с помощью библиотеки «keras». Подробно о настроечных параметрах можно узнать на официальном сайте [6]. В частности, использовались методы обучения полносвязных нейронных сетей (ПНС). ПНС являются одним из наиболее распространенных типов нейронных сетей, используемых для обработки сложных данных. Они состоят из множества нейронов, которые соединены между собой взвешенными связями.

Каждый нейрон в ПНС принимает входные данные, умножает их на свои веса и передает результат следующему нейрону. В конце сети находится выходной слой, который предсказывает результат. Пример ПНС представлен на рис. 2.

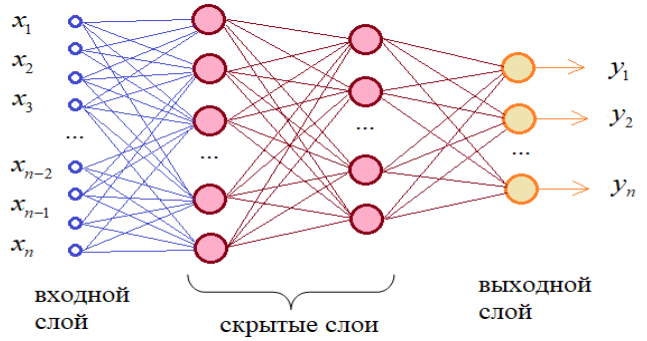

Рис. 2. Пример полносвязной нейронной сети

В этой сети каждый нейрон входного слоя соединен со всеми нейронами скрытого слоя, а каждый нейрон скрытого слоя соединен со всеми нейронами выходного слоя.

Для обучения ПНС используется метод обратного распространения ошибки. В этом методе сначала сеть получает входные данные, затем вычисляется ошибка и она распространяется обратно через сеть, корректируя веса.

C. Результаты эксперимента

Обученная модель занимается прогнозированием поведения величин, поэтому для детектирования отклонения поведения реальных данных от прогнозируемых необходимо ввести уставки. Из графика, представленного на рис. 3 видно, что ошибка присутствует по параметру температуры T и давления P, введём уставки по данным величинам:

- ошибка T >8,3 – предупредительный сигнал;
- ошибка T >13,5 – аварийный сигнал;
- ошибка P >0,1 – предупредительный сигнал;
- ошибка P >0,24 – аварийный сигнал.

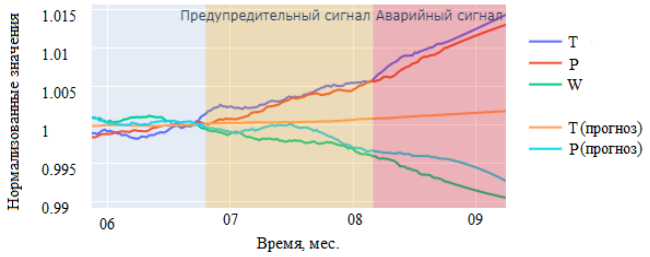

Рис. 3. Результат работы модели

Вычислим ошибку прогнозирования, на рис. 4 видно, что для подшипника наблюдается рост разладки температуры масла. На примере выявления аномального состояния подшипника, рассмотренного при анализе исходных данных, подтверждена эффективность обученной модели.

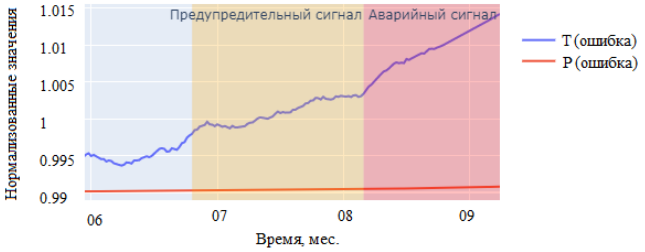

Рис. 4. Нормализованная ошибка прогнозирования

V. Заключение

По результатам выполненных исследований была разработана система, включающая в себя совокупность применения методов локальной диагностики с использованием диагностических признаков и методов машинного обучения. Ввиду отсутствия статистических данных по другим аномалиям остается проблема классификации этих аномалий. В дальнейшем, при получении данных о других аномальных режимах работы, планируется произвести экспертную разметку и определить возможные методы классификации, и сформировать дополнительные диагностические признаки.

Список литературы

[1] ГОСТ 533-2000. Издания. Машины электрические. Вращающиеся. Генераторы. Минск, 2000, 24 с.

[2] Розум Т.И., Полищук В.И. Разработка архитектуры интеллектуальной системы функциональной диагностики турбогенератора // Вестник науки Сибири. 2015. Спецвыпуск (15), с. 83-86.

[3] Strid I., Walentin K. Block Kalman Filtering for Large-Scale DSGE Models. Computational Economics, 2009, Sveriges Riksbank Working Paper Series, no. 224. Available at: https://www.researchgate.net/publication/46547611 (Accessed 21 March 2023).

[4] Коган Ф.Л. Аномальные режимы мощных турбогенераторов. М.: Энергоатомиздат, 1987. 188 с.

[5] Субботин С.В., Большаков Д.Ю. Применение байесовского классификатора для распознавания классов целей // Журнал Радиоэлектроники, 2006, № 4

[6] Keras API reference. Available at:) https://keras.io/api/ (accessed 21 March 2023).

Глубокие пирамидальные нейронные сети быстрого обучения для корреляционной обработки сигналов и изображений

А. Ю. Дорогов
Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» им. В. И. Ульянова (Ленина)
vaksa2006@yandex.ru

***Аннотация*. В работе рассматривается класс быстрых нейронных сетей с пирамидальной структурой, предназначенных для корреляционной цифровой обработки сигналов и изображений. Показано, что предложенная структура пирамидальной нейронной сети является частным вариантом структуры быстрого преобразования Фурье. Предложен абсолютно-сходящийся алгоритм быстрого обучения пирамидальной сети к произвольному набору функций. Доказано, что быстрая пирамидальная сеть является нейронной сетью глубокого обучения, а самоподобная структура позволяет дообучать сеть к новым данным без необходимости полного переобучения сети.**

Ключевые слова: быстрое перестраиваемое преобразование; нейронная сеть; пирамидальная структура; глубокое обучение; адаптивная цифровая обработка сигналов

I. Введение

В работе [1] была предложена архитектура пирамидальной нейронной сети (PyraNet) предназначенной для визуального распознавания образов. Пирамидальная сеть PyraNet имеет иерархическую многослойную структуру, обрабатывающую 2D образы. Выходами сети является 1D слой, представляющий категории входных образов. Пирамидальная нейронная сеть для своего обучения использует тот же арсенал методов обратного распространения ошибок, что и классические многослойные нейронные сети. Общий недостаток этих методов, не гарантируемая сходимость по ошибкам обучения к глобальному минимуму и значительные вычислительные затраты особенно для глубоких нейронных сетей [2].

В данной работе будут рассмотрены пирамидальные сети с регулярной самоподобной структурой. Для сетей данного типа можно предложить быстрые алгоритмы обучения, сходящиеся за конечное число шагов. Этот класс сетей имеет глубокую связь с алгоритмом быстрого преобразования Фурье и иначе называется быстрыми перестраиваемыми преобразованиями [3].

Возможность перестройки значений весовых коэффициентов и многослойная структура алгоритма роднит быстрые перестраиваемые преобразования с многослойными нейронными сетями прямого распространения. В рамках данной парадигмы, быстрые линейные перестраиваемые преобразования являются частным случаем многослойных нейронных сетей и отличаются от последних линейными функциями активации и нулевыми смещениями в нейронах. Нейронные сети данного типа получили название быстрые нейронные сети (БНС) [4].

Благодаря своей структуре БНС обладают специфичными алгоритмами обучения принципиально отличными от классического ErrorBackPropagation отсутствием обратного распространения ошибки, что обеспечивает высокую скорость обучения и абсолютную сходимость. Идея метода обучения БНС к одной или нескольким функциям основана на представлении каждой функции заданного набора в виде предфрактального произведения, отвечающего мультипликативной форме представления элементов матрицы быстрого преобразования.

В работах [5, 6] были рассмотрены реализации одноканальных дискриминаторов сигналов и изображений в классе быстрых нейронных сетей с одним выходом. В данной работе показано использование пирамидальной БНС для построения многоканального дискриминатора сигналов и изображений. Дано описание математической модели одномерной и двумерной БНС, представлены методы построения топологии и обучения БНС для задачи корреляционных измерений в дискретном пространстве.

Одним из основных способов распознавания сигналов при корреляционных измерениях состоит в сопоставлении сигнала с эталоном. Если сходство между неизвестным сигналом и эталоном велико, то сигнал помечается как соответствующий эталонному. Простейшей мерой сходства является линейный дискриминант Фишера [7]. В частном случае этот дискриминант представляет собой меру взаимной энергии сигналов и выражается через нормированное скалярное произведение

$$d = (x,e) \Big/ \sqrt{(x,x)(e,e)} > \alpha \ , \qquad (1)$$

где x – неизвестный сигнал представленный вектором, e – вектор эталонного сигнала, скобки $(,)$ – обозначают скалярное произведение векторов, скаляр α определяет пороговый уровень различения сигналов. В многоканальном дискриминаторе используются несколько эталонных сигналов.

II. Пирамидальная быстрая нейронная сеть

Алгоритм быстрого преобразования может быть представлен многослойным графом, связывающим между собой настраиваемые базовые операции, которые

в дальнейшем мы будем называть нейронными ядрами. Рассмотрим быстрое одномерное преобразование в топологии Гуда [8] (рис. 1).

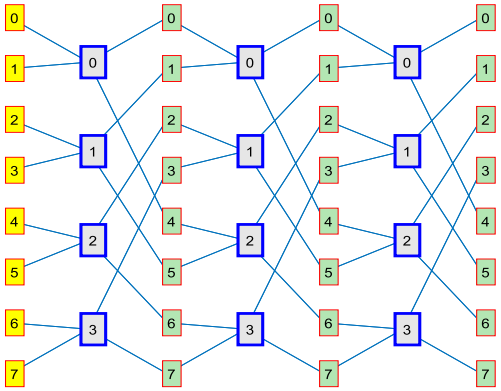

Рис. 1. Топологическая схема Гуда для размерности быстрого преобразования 8 с явным выделением базовых операций

В работе [4] показано, что топологическая модель алгоритма быстрого преобразования определяется кортежами

$$\begin{aligned} U^m &= \langle v_{m-1} v_{m-2} \ldots v_0 u_{n-1} u_{n-2} \ldots u_m \rangle, \\ V^m &= \langle v_m v_{m-1} \ldots v_0 u_{n-1} u_{n-2} \ldots u_{m+1} \rangle, \\ i^m &= \langle v_{m-1} \ldots v_0 u_{n-1} u_{n-2} \ldots u_{m+1} \rangle. \end{aligned} \quad (2)$$

Здесь m – номер слоя, локальные переменные u_m, v_m определяют позиционные номера рецепторов и аксонов базовых операций в слое m. Кортежи используются для поразрядного представления чисел в позиционной системе счисления. Например, для системы счисления с основанием 2 имеем:

$$u = \langle u_{n-1} u_{n-2} \ldots u_0 u_1 \rangle = u_{n-1} 2^{n-1} + u_{n-2} 2^{n-2} + \ldots + u_1 2 + u_0 .$$

В кортеже крайняя левая цифра считается старшим разрядом. Значение U^m определяет глобальный номер рецептора, значение V^m – глобальный номер нейрона, а i^m – номер нейронного ядра в слое m. Нумерация слоёв сети начинается с нуля, общее количество слоёв равно n.

Из выражения (2) следует, что для нулевого слоя номер базовой операции (нейронного ядра) определяется выражением:

$$i^0 = \langle u_{n-1} u_{n-2} \ldots u_1 \rangle,$$

а глобальный номер рецептора нулевого нейронного слоя выражением:

$$U^0 = \langle u_{n-1} u_{n-2} \ldots u_0 \rangle . \quad (3)$$

Локальные переменные u_0, v_0 определяют позиционный номер рецептора и позиционный номер аксона в пределах каждого ядра нулевого слоя (нумерация рецепторов и аксонов начинается с нуля). Будем полагать, что число p_0 определяет число рецепторов ядра нулевого слоя, а число g_0 – число аксонов. Аналогичные обозначения p_m, g_m, где $m = 0,1,\ldots,n-1$, будем использовать для обозначения размерностей рецепторных и аксоновых полей остальных слоёв сети.

Выберем значения $g_m = 1$ для $m = 1,2,\ldots,n-1$, а для $m = 0$ сохраним произвольное значение g_0. В этом случае из (2) следует, что аксоны последнего слоя получат глобальные позиционные номера

$$V^{n-1} = \langle 0_{n-1} 0_{n-2} \ldots 0_1 v_0 \rangle .$$

Таким образом, нейронная сеть будет иметь ровно g_0 выходов, а из (3) следует, что число входов будет равно $N = p_0 \cdot p_1 \cdot \ldots \cdot p_{n-1}$. Построенная сеть является пирамидальной, с размерностью N по входу и g_0 по выходу. На рис. 2 приведён пример трёхслойной пирамидальной сети для структуры $(p_0, p_1, p_2) = (4,2,2)$, $(g_0, g_1, g_2) = (3,1,1)$.

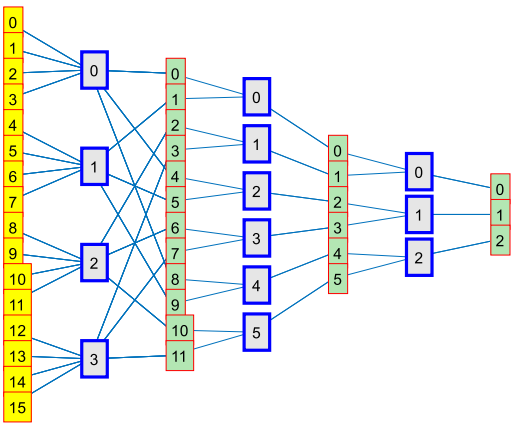

Рис. 2. Треслойная пирамидальная БНС с регулярной топологией

Детали построения топологического графа БНС изложены в работе [4]. Для БНС доказана обобщённая теорема факторизации [4], согласно которой элементы матрицы преобразования представимы через произведение элементов базовых операций:

$$h(U,V) = w_{i^0}^0 (u_0, v_0) w_{i^1}^1 (u_1, v_1) \ldots w_{i^{n-2}}^{n-2} (u_{n-2}, v_{n-2}) w_{i^{n-1}}^{n-1} (u_{n-1}, v_{n-1}) \quad (4)$$

Здесь элементы матриц базовых операций $W_{i^m}^m$ обозначены через $w_{i^m}^m (u_m, v_m)$, где u_m, v_m – определяют номер строки и номер столбца матрицы, m – номер слоя, и i^m – номер базовой операции в пределах слоя.

В работе [6] приведён алгоритм мультипликативной декомпозиции произвольной функции заданной на дискретном интервале длиной $N = p_0 p_1 \cdots p_{n-1}$. Мультипликативная декомпозиция имеет вид:

$$f(u) = f_0 \langle u_{n-1} u_{n-2} \ldots u_0 \rangle = \phi_{i^0} (u_0) \phi_{i^1} (u_1) \ldots \phi_{i^{n-2}} (u_{n-2}) \phi_{i^{n-1}} (u_{n-1}), \quad (5)$$

где аргумент представляется в виде числа в многоосновной системе счисления:

$$\begin{aligned} u = \langle u_{n-1} u_{n-2} \ldots u_0 \rangle &= u_{n-1} p_{n-2} p_{n-3} \ldots p_0 + \cdots \\ \cdots + u_{n-2} p_{n-3} p_{n-4} \ldots p_0 + \ldots + u_1 p_0 + u_0 . \end{aligned}$$

Здесь $u_i \in [0,1,\dots p_i - 1]$ – разрядные переменные. Нетрудно заметить, что выражения (4) и (5) подобны, учитывая, что для построенной пирамидальной сети

$$i^m = \langle 0_{m-1} \dots 0_1 v_0 u_{n-1} u_{n-2} \dots u_{m+1} \rangle,$$

можно записать следующее правило обучения нейронных ядер:

$$w_{i^0}^0 (u_0, v_0) = \phi_{i^0}^k (u_0), \quad m = 0,$$
$$w_{i^m}^m (u_m, 0) = \phi_{i^m}^k (u_m), \quad m = 1,2,\dots,n-1,$$
$$i^m = \langle v_0 u_{n-1} u_{n-2} \dots u_{m+1} \rangle,$$

где k – номер эталонной сигнальной функции. Взаимно-однозначное соответствие $k \leftrightarrow v_0$ определяет упорядочение сигнальных функций в выходном слое.

III. Задача многоканальной корреляции

Будем полагать, что входной и эталонные сигналы нормированы к энергии, так что $(x,x) = 1$ и $(e,e) = 1$. В этом случае дискриминант определяется скалярным произведением

$$d = (x,e).$$

Скалярное произведение можно рассматривать как произведение вектора-строки x на одно-столбцовую матрицу $H = e'$. Для многоканального дискриминатора матрица H будет состоять из g_0 столбцов, а правило вычисления определяется выражением:

$$d(k) = \sum_U x(U) h(U,V).$$

Будем полагать, что матрица H является матрицей быстрого пирамидального преобразования с топологией Гуда. Поскольку сеть имеет g_0 выходов, то

$$V^{n-1} = \langle 0_{n-1} 0_{n-2} \dots 0_1 v_0 \rangle.$$

На каждом выходе будет формироваться значение скалярного произведения, отвечающего эталонному сигналу. Пирамидальная сеть, показанная на рис. 2 может быть обучена к трём сигнальным функциям, заданным на интервале длинной 16.

Замечание. Поскольку для предложенной архитектуры пирамидальной сети выполняются условия: $g_m = 1$ для всех $m = 1,2,\dots,n-1$, то из (2) следует

$$U^m = \langle 0_{m-1} 0_{m-2} \dots 0_1 v_0 u_{n-1} u_{n-2} \dots u_m \rangle,$$
$$V^m = \langle 0_m 0_{m-1} \dots 0_1 v_0 u_{n-1} u_{n-2} \dots u_{m+1} \rangle, \qquad (6)$$
$$i^m = \langle 0_{m-1} \dots 0_1 v_0 u_{n-1} u_{n-2} \dots u_{m+1} \rangle.$$

При варьировании в кортеже V^m переменных v_0 и u_i кортеж определяет множество номеров аксонов в пределах слоя. Подчеркнём, что в БНС рецепторные поля нейронных ядер не пересекаются, и каждый нейрон слоя имеет точно один аксон [4].

Нетрудно заметить, что пирамидальная нейронная сеть предложенной архитектуры, распадается на независимые группы нейронов индексированных разрядом v_0. Каждая группа нейронов способна обучаться независимо от других групп. Таким образом, пирамидальная нейронная сеть рассматриваемого типа обладает уникальной возможностью последовательного дообучения к эталонам без потери ранее накопленных знаний.

IV. Пластичность пирамидальной нейронной сети

В биологии термин пластичность используется, как качественная характеристика способности нейронной сети обучаться при воздействии внешних факторов. Для искусственных нейронных сетей адекватной количественной оценкой может служить число независимых настроек, называемое также числом степеней свободы. Это значение, как правило, меньше полного количества настраиваемых синаптических весов нейронной сети. Для БНС получены точные формулы расчёта числа степеней свободы [4]. Исходными данными для расчёта является структурная модель нейронной сети. Структурная модель это взвешенный граф, вершинами которого являются нейронные ядра. Вес каждого ядра определяется парой чисел, представляющих размерность по входу и выходу, а вес дуг определяется рангами операторов межъядерной связи. На рис. 3 представлена структурная модель для сети, показанной на рис. 2.

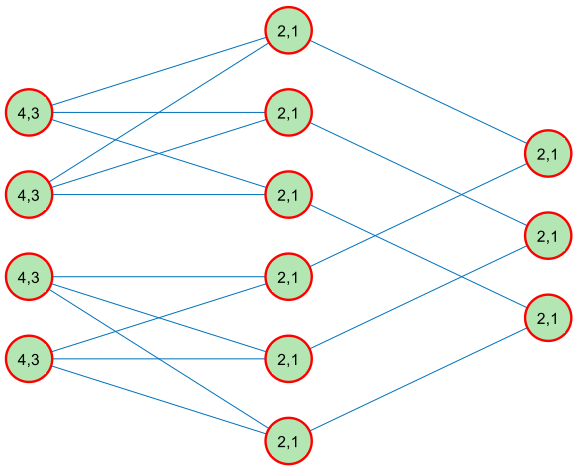

Рис. 3. Структурная модель пирамидальной нейронной сети

Для БНС ранги операторов межъядерных связей равны 1 и на графе структурной модели условно не показаны. Формула расчёта числа степеней свободы для БНС имеет вид:

$$S(H) = \sum_{m=0}^{n-1} p_m g_m q_m - \sum_{m=0}^{n-2} D_m,$$

где p_m, g_m размерности рецепторного и аксонового поля ядра в слое m, q_m – число ядер в слое, D_m – количество одноранговых связей в межслойном переходе с номером m. Для структурной модели, представленной на рис. 3 непосредственным подсчётом получим

$S(H) = 4 \cdot 3 \cdot 4 + 2 \cdot 1 \cdot 6 + 2 \cdot 1 \cdot 3 - 12 - 6 = 48$. Напомним, что данная сеть может обучиться к трём эталонным функциям, заданным на интервале длиной 16. При произвольном выборе трёх функций необходимо задать 48 значений, что совпадает с числом степеней свободы пирамидальной сети. Таким образом, рассматриваемая сеть является глубокой в том смысле, что её потенциал обучения используется полностью, и покрывает все допустимое многообразие эталонных сигналов.

Архитектура быстрой пирамидальной нейронной сети легко обобщается на многомерный случай [5]. Выражения (6) для топологии сети в этом случае примут вид:

$$U_*^m = \left\langle 0_{m-1}^* 0_{m-2}^* \ldots 0_1^* v_0^* u_{n-1}^* u_{n-2}^* \ldots u_m^* \right\rangle,$$
$$V_*^m = \left\langle 0_m^* 0_{m-1}^* \ldots 0_1^* v_0^* u_{n-1}^* u_{n-2}^* \ldots u_{m+1}^* \right\rangle,$$
$$i_*^m = \left\langle 0_{m-1}^* 0_{m-2*}^* \ldots 0_1^* v_0^* u_{n-1}^* u_{n-2}^* \ldots u_{m+1}^* \right\rangle,$$

Отсюда следует правило обучения нейронной сети:

$$w_{i_x^m, i_y^m}^m \left(u_m^y u_m^x ; v_m^y v_m^x \right) = f_{i_x^m, i_y^m}^k \left(u_m^y, u_m^x \right), \quad m = 0,$$
$$w_{i_x^m, i_y^m}^m \left(u_m^y u_m^x ; 0_m^y 0_m^x \right) = f_{i_x^m, i_y^m}^k \left(u_m^y, u_m^x \right), \quad m > 0, .$$
$$i_*^m = \left\langle 0_{m-1}^* 0_{m-2*}^* \ldots 0_1^* v_0^* u_{n-1}^* u_{n-2}^* \ldots u_{m+1}^* \right\rangle.$$

Здесь $w_{i_x^m, i_y^m}^m \left(u_m^y u_m^x ; v_m^y v_m^x \right)$ – двумерные нейронные ядра, $f_{i_x^m, i_y^m}^k \left(u_m^y, u_m^x \right)$ – множители мультипликативного разложения эталонного изображения, x, y – пространственные координаты. Взаимно-однозначное соответствие $k \leftrightarrow \left(v_m^y, v_m^x \right)$ определяет упорядочение эталонных функций в выходной плоскости. На рис. 4 представлен топологический граф коррелирующей пирамидальной сети для изображения $N \times N = 2^3 \times 2^3$ со структурными параметрами $g_0^x = 4$, $g_0^y = 2$. Сеть способна выполнять корреляционную обработку для восьми изображений.

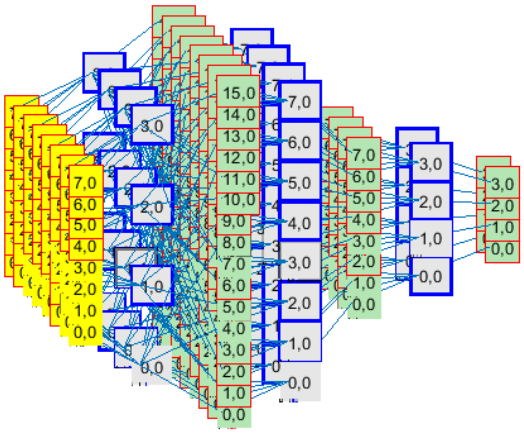

Рис. 4. Топология регулярной пирамидальной 2D сети

V. Заключение

Пирамидальные регулярные нейронные сети можно рассматривать как частный случай быстрых нейронных сетей, которые в свою очередь относятся к широкому классу самоподобных многослойных нейронных сетей [9]. Самоподобные многослойные сети с регулярной структурой обладают уникальным свойством аналитического представления графа топологической модели, что позволяет разработать быстрые абсолютно сходящиеся алгоритмы обучения с конечным числом вычислительных операций. Кроме того, процесс обучения для каждого эталона может выполняться независимо от других, т. е. пирамидальная сеть данного типа обладает важным качествам накапливать знания, без необходимости переобучения сети при добавлении новых данных. В данной статье вывод основных соотношений основан на алгоритме быстрого преобразования с топологией Гуда, подобные выражения могут быть получены для топологии Кули–Тьюки или любой иной топологии быстрых преобразований.

Представленные в работе результаты показывают, что пирамидальные сети могут быть эффективно использованы для построения многоканальных корреляторов сигналов и изображений. Подобным образом могут быть построены дискриминаторы для локализации объектов в многомерных пространствах. Более того, регулярный лес корреляционных сетей позволяет реализовать быстрые нейронные сети глубокого обучения [10], способные дообчаться без потери ранее наколенных знаний. Поскольку подобные сети имеют гарантированное время обучения при абсолютной сходимости алгоритма, то они могут эффективно использоваться в самообучающихся робототехнических системах реального времени.

Список литературы

[1] S.L. Phung and A. Bouzerdoum, “A pyramidal neural network for visual pattern recognition,” IEEE Transactions on Neural Networks, vol. 18, no. 2, pp. 329–343. 2007.

[2] Ihsan Ullahy and Alfredo Petrosinoy About Pyramid Structure in Convolutional Neural Networks arXiv:1608.04064v1 [cs.CV] 14 Aug 2016.

[3] Солодовников А.И., Спиваковский А.М. Основы теории и методы спектральной обработки информации. Л., 1986. 272 с.

[4] Дорогов А.Ю. Теория и проектирование быстрых перестраиваемых преобразований и слабосвязанных нейронных сетей. СПб.: «Политехника», 2014. 328 с.

[5] Дорогов А.Ю. Корреляционный дискриминатор изображений в классе быстрых нейронных сетей // XXV Международная конференция по мягким вычислениям и измерениям (SCM-2022). Сборник докладов. Санкт-Петербург. 25–27 мая 2022. СПб.: СПбГЭТУ «ЛЭТИ». с. 134-137.

[6] Дорогов А.Ю. Корреляционный дискриминатор сигналов в классе быстрых нейронных сетей // III Международная конференция по нейронным сетям и нейротехнологиям (NeuroNT'2022): сб. докладов. СПб.: СПбГЭТУ «ЛЭТИ», 16 июня 2022. с. 59-62.

[7] Фишер Р.А. Статистические методы для исследователей. Москва, Госизадат, 1958. 267с.

[8] Good I.J. The Interaction Algorithm and Practical Fourier Analysis // Journal of Royal Statistical Soseity. Ser.B. 1958. Vol.20. No.2. P.361-372.

[9] Дорогов А.Ю. Самоподобные структуры многослойных нейронных сетей. // XXII Международная научно-техническая конференция «Нейроинформатика-2020» (10-16 октября 2020 г.): Сб. научных трудов. М. НИЯУ МИФИ, 2020. с. 214-224.

[10] Дорогов А.Ю. Быстрые нейронные сети глубокого обучения. // III Международная научная конференция по проблемам управления в технических системах (CTS'2019): Сб. докладов. 30 октября – 1 ноября 2019 г. СПб.: СПбГЭТУ «ЛЭТИ». С. 275-280.

Нейросетевое управление параметрами окружающей среды в неонатальных инкубаторах

С. В. Фролов[1], А. Ю. Потлов, А. А. Коробов, К. С. Савинова
Тамбовский государственный технический университет
[1]sergej.frolov@gmail.com

***Аннотация*. Неонатальный инкубатор является многосвязным, нелинейным, нестационарным, стохастическим объектом. Использование традиционных методов управления таким объектом не обеспечивает заданного качества регулирования. Имеются требования к высокоточному поддержанию в инкубаторе параметров микроклимата. Для управления многосвязными выходными параметрами инкубатора будет использован предложенный авторами метод градиентного нейросетевого управления. Нейросетевой блок и блок физического объекта (неонатальный инкубатор) образует динамическую систему. Динамическая система описывается дискретной моделью, где множеством управляющих координат на шаге дискретного процесса являются весовые коэффициенты нейронной сети. Цель управления задаётся в виде неотрицательной функции и характеризует отклонения от заданных параметров температуры и влажности. На выходе нейронной сети на основе значений множества весовых коэффициентов формируется вектор управлений, влияющих на изменение параметров микроклимата. Основу нейросетевой системы управления составляет сеть типа MLP. Алгоритм нейросетевого управления основан на коррекции весовых коэффициентов с использование метода градиентного управления и обратного распространения ошибки. Для решения проблемы устойчивости процесса управления применяется метод регуляризации. Планируется практическая реализация метода градиентного нейросетевого управления в неонатальных инкубаторах с использованием мини-компьютера «Raspberry Pi 4B 4GB RAM» и языка программирования Python.**

Ключевые слова: нейросетевое управление; градиентный метод; нейронные сети; неонатальный инкубатор

В медицине уход за недоношенными детьми является одной из самых чувствительных и деликатных областей [1]. Преждевременные роды являются одной из главных причин детской смертности и инвалидности [2]. У недоношенных младенцев в полной мере не обеспечиваются процессы терморегуляции. Таким детям необходима чистая и тёплая среда [3].

Обеспечить поддержание заданных параметров микроклимата для новорожденных детей, повысить их темпы роста, устойчивость к заболеваниям и выживание возможно с помощью неонатального инкубатора (кувеза) [3].

Первой серьезной попыткой улучшить термозащиту новорожденных в 1835 году стало изобретение известным русским врачом И.Ф. Рюлем металлической ванны с двойными стенками, наполненной тёплой водой, которое было актуально вплоть до 1878 г. Благодаря французскому акушеру С.Э. Тарнье стало известно, что для выхаживания недоношенных младенцев недостаточно поддержания одной и той же температуры, также важно поддерживать стерильную, влажную среду. Исходя из своих исследований, Тарнье в 1881 году представил свое устройство для выхаживания детей в парижском роддоме. Кувез был выполнен из стекла и дерева в виде ящика с водным подогревом. Применение этого медицинского изделия позволило снизить младенческую смертность на 28 %.

Первый прототип современного инкубатора был создан в 1891 году французским доктором А. Лайоном. Устройство представляло собой стеклянный бокс, в который нагнетался теплый чистый воздух.

В первой половине XX века был предложен механизм для дополнительной подачи кислорода в инкубатор, а также была опубликована статья о повышении выживания новорожденных в среде с обогащенной влажностью [4].

В 1947 году американский физик Чеппл создал для медицинских учреждений неонатальный инкубатор с системой управления по температуре.

Функциональная схема современного неонатального инкубатора представлена на рис. 1.

Неонатальный инкубатор является многосвязным, нелинейным, нестационарным, стохастическим объектом. Следует отметить, что имеются требования к высокоточному поддержанию в инкубаторе параметров микроклимата, а именно к температурным режимам и влажности. Система контроля параметров жизнеобеспечения младенцев является наиболее важной частью детского инкубатора. Добиться комфортных условий внутри инкубатора (соответствующей теплозащиты, уровня влажности, концентрации кислорода) можно благодаря надёжной системе автоматического регулирования.

Исследование выполнено за счет гранта Российского научного фонда №23-29-00763, https://rscf.ru/project/23-29-00763/

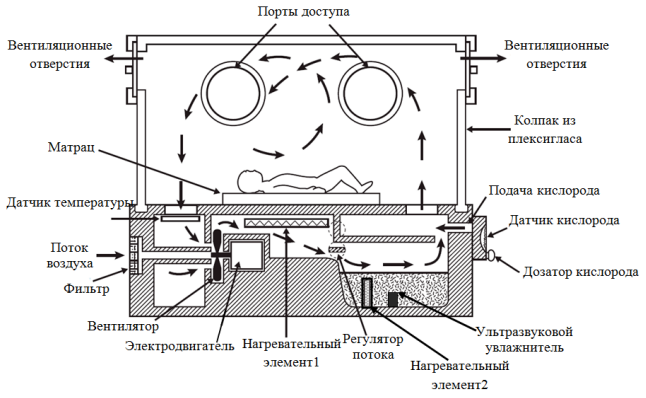

Рис. 1. Функциональная схема инкубатора для новорожденных

В настоящее время проблеме управления параметрами окружающей среды в неонатальных инкубаторах посвящено много работ. В исследованиях [5,6] рассматривается настройка параметров динамического матричного управления в качестве контролера для управления температурой и влажностью в инкубаторе на основе сравнения результатов двух методов идентификации. Авторами [7] показана модель инкубатора, направленная на изучение регулирования температуры при взаимодействии тепловых процессов инкубатора и ребёнка с применением контроллера, реализующего прогнозирующее управление параметрами. Авторами [8] предлагается усовершенствование управления многопараметрическими процессами (влажность и температура в инкубаторе) с помощью алгоритма, использующего адаптивный весовой коэффициент для уменьшения между связями контурами управления. В статьях [9,10] приведён алгоритм прогнозирующего многопараметрического контроля температурой и влажностью в инкубаторе для устранения ошибок, вызванных влияниям взаимосвязи двух контуров управления. В работе [11] дан систематический подход к проектированию адаптивного прогнозирующего управления температурой и влажностью в инкубаторе с помощью корректировки веса выходной ошибки для повышения эффективности управления. Авторами [12] разработана модель, учитывающая тепловой баланс и климатические взаимодействия внутри инкубатора, а также потери тепла при испарении. Предложен обобщённый прогнозирующий контроллер для точного регулирования температуры и относительной влажности внутри инкубатора. В исследовании [13] применяют контроллер на основе генетического алгоритма для управления уровнем влажности в инкубаторе, который имеет преимущество при изменяющейся динамике процессов внутри инкубатора по сравнению с классическим ON-OFF или PID управлением. В ряде работ применяются возможности численной оптимизации и нейронных сетей для усовершенствования классических способов управления в инкубаторах. В работе [14] применяют метод роя частиц для настройки PID регулятора, отвечающего за уровень температуры воздуха внутри инкубатора. Проводятся исследования в области проектирования ПИД-регуляторов в промышленности, результаты которых могут быть полезны при проектировании инкубаторов для новорождённых. В исследовании [15] разработан PID-регулятор на основе программируемой пользователем вентильной матрицы для регулирования температуры в холодильной системе.

Использование традиционных методов управления таким объектом не всегда обеспечивает заданного качества регулирования. Для управления многосвязными выходными параметрами инкубатора y1(t), y2(t) будет использован метод нейросетевого управления. В настоящее время использование методов нейросетевого управления привлекает большое число исследователей [16]. Особенно это относится к управлению многосвязными, нелинейными, нестационарными, стохастическими объектами. Для этих целей разработано большое число методов нейросетевого управления динамическими системами: Neurocontrol learning based on mimic, Controller Modeling, Supervised Learning Using an Existing Controller, Generalized Inverse Neurocontrol, Direct Inverse Neurocontrol, Specialised Inverse Neurocontrol, Backpropagation Through Time, Internal Model Control, NN Predictive Control, Model Predictive Control, Neural Generalized Predictive Control, Adaptive Critics, Incremental Clustered Control Networks, Multiple Paired Forward and Inverse Models, Multiple Switched Models, NNPID Auto-tuning, Neuromorphic PID Self-tuning, Parallel Neurocontrol, Stable Direct Adaptive Control, NARMA L2 Feedback Linearization Control, Additive Feedforward Control, Adaptive Inverse Control, Adaptive Inverse Control based on Linear and Nonlinear Adaptive Filtering, Internal Model Control, Model Reference Adaptive Control, Neural Adaptive Control и др. К недостаткам известных методов нейросетевого управления следует отнести необходимость обучения нейронной сети с использованием большого объема входных и выходных данных о динамике объекта, что требует значительных ресурсов.

Нами разработан новый метод нейросетевого управления многосвязным, нелинейным, нестационарным, стохастическим объектом [17]. В основе представленного решения применяется градиентный метод для управления киберфизическими системами, предложенный А.Д. Фрадковым [18]. Преимуществом разработанного метода является его способность к самонастройке в условиях действия неконтролируемых возмущающих воздействий и отсутствие необходимости в обучении нейронной сети на основе данных о динамике объекта.

Структура системы управления представляется как динамическая система (рис. 2) и включает нейросетевой блок и неонатальный инкубатор.

Входными управляющими параметрами (рис. 1, рис. 2), которые обеспечивают высокоточное поддержание заданных значений температуры $y_{з1}$ и влажности $y_{з2}$ внутри инкубатора, могут быть скорость вращения вентилятора $u_1(t)$, мощности нагревателя1 $u_2(t)$ и нагревателя2 $u_3(t)$, положение регулятора потока $u_4(t)$, мощность ультразвукового увлажнителя $u_5(t)$.

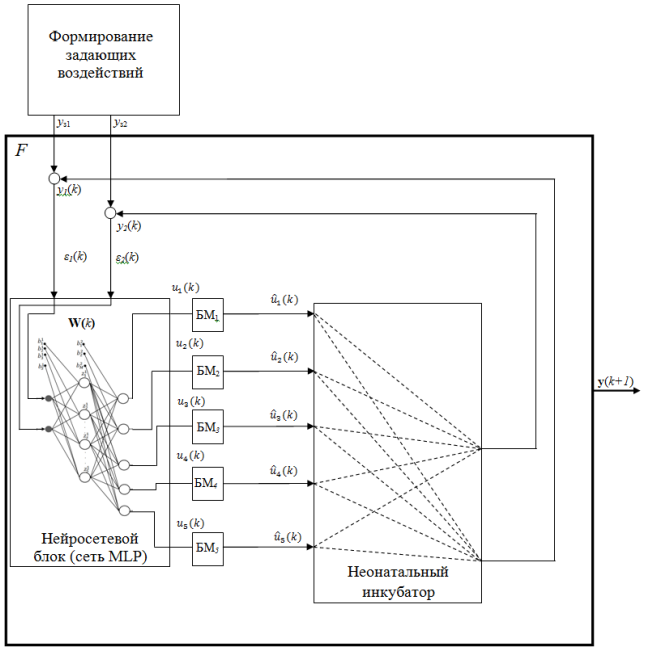

Рис. 2. Структура нейросетевой динамической системы

Для задачи управления удобно описывать динамическую систему дискретной моделью:

$$\mathbf{y}(k+1)=F(\mathbf{y}(k),\mathbf{W}(k)),$$

где $\mathbf{y}(k)=(y_1(k),\ y_2(k))$ – вектор состояния выхода динамической системы на k-ом шаге процесса (вектор управляемых координат); $\mathbf{W}(k)$ – множество управляющих координат на k-ом шаге процесса, k=0, 1, 2, ... (весовых коэффициентов нейронной сети).

Дискретная модель задаётся набором отображения системы $F(k)$. На вход системы поступает на k-ом шаге вектор задающего воздействия: $\mathbf{y}_з(k)=(y_{з1}(k),\ y_{з2}(k)$, значения которого определяется в блоке формирования задающих воздействия.

Цель управления задаётся в виде неотрицательной функции $e(y(k+1))\le\Delta$ при $k>k^*$, где $\Delta>0$ – заданное значение порога точности задачи; k^* – номер шага, при котором достигается цель управления.

Вектор рассогласования $\boldsymbol{\varepsilon}(k)$ задающих воздействий $\mathbf{y}_з(k)$ и вектора управляемых координат $\mathbf{y}(k)$ поступает на нейросетевой блок с элементов сравнения на k-ом шаге:

$$\boldsymbol{\varepsilon}(k)=\mathrm{y}_з(k)-\mathrm{y}(k),$$

где составляющие вектора $\boldsymbol{\varepsilon}(k)$, определяются как $\boldsymbol{\varepsilon}(k)=(\varepsilon_1(k),\ \varepsilon_2(k))$.

Функция цели управления $e(\mathbf{y}(k+1))$ представляется в виде:

$$e(\mathbf{F}(\mathbf{y}(k),\mathbf{W}(k)))=(\mathbf{y}(k)-\mathbf{y}_з(k))^T(\mathbf{y}(k)-\mathbf{y}_з(k))=\sum_{n=1}^{2}\varepsilon_n(k)^2$$

Нейросетевой блок на основе значений множества $\mathbf{W}(k)$ и входа $\boldsymbol{\varepsilon}(k)$ формирует вектор выходных параметров $\mathbf{u}(k)=(u_1(k),\ ...,\ u_5(k))$, где каждый элемент вектора $\mathbf{u}(k)$ связан с объектом управления через блок масштабирования (БМ).

Для построения нейросетевого блока применяются нейронные сети прямого распространения, такие как многослойный персептрон (Multi-Layer Perceptron – MLP).

Алгоритм нейросетевого управления основан на коррекции весовых коэффициентов с использование метода градиентного управления [17] и метода обратного распространения ошибки и состоит из следующих этапов. 1) Старт алгоритма нейросетевого управления. Инициализация весовых коэффициентов нейронной сети. 2) Вычисление выходных сигналов нейронов внутреннего и внешнего слоя нейронов и их производных. 3) Вычисление локальных градиентов (метод обратного распространения ошибки). 4) Настройка составляющих множества управляющих координат – весовых коэффициентов нейронной сети (метод обратного распространения ошибки). 5) Шаг процесса увеличивается на 1, происходит переход на этап 2) алгоритма нейросетевого управления. Система управления начинает терять устойчивость с течением времени из-за накопления ошибок округления, что приводит к росту весовых коэффициентов нейронной сети. Для решения этой проблемы применяется метод регуляризации [19]. Для того, чтобы ограничить рост составляющих множества весовых коэффициентов $\mathbf{W}$ функция цели управления записывается в виде:

$$\tilde{e}(\mathbf{y}(k+1))=\sum_{n=1}^{5}\varepsilon_n(k)^2+\Omega(\mathbf{W}(k)),$$

$$\Omega(\mathbf{W}(k))=\frac{1}{2}\lambda\left[\left(\sum_{n=1}^{2}\sum_{s=1}^{S}w_{ns}^{1}(k)\right)^2+\left(\sum_{m=1}^{5}\sum_{s=1}^{S}w_{sm}^{2}(k)\right)^2+\left(\sum_{n=1}^{2}\sum_{s=1}^{S}b_{ns}^{1}(k)\right)^2+\left(\sum_{m=2}^{5}\sum_{s=2}^{S}b_{ms}^{1}(k)\right)^2\right],$$

где λ – коэффициент регуляризации. $w_{ns}^{1}(k), w_{sm}^{2}(k), b_{ns}^{1}(k), b_{ms}^{1}(k)$ – весовые коэффициенты нейронной сети с одним внутренним слоем (настроечные параметры). В этом случае на каждом шаге изменение множества $\mathbf{W}(k)$ происходит в соответствии с зависимостью:

$$\mathbf{W}(k+1)=\mathbf{W}(k)-\eta\nabla_{\mathbf{W}}\tilde{e}(\mathbf{W}(k)),$$

где $\nabla_{\mathbf{W}}$ – вектор градиента, $\eta\ge0$ коэффициент настройки алгоритма градиентного нейросетевого управления.

Для реализации алгоритма необходима априорная информация в виде матрицы Якоби, которая определяется в окрестностях рабочей точки ($\mathbf{y}_0$, $\mathbf{u}_0$):

$$\mathbf{J}(\mathbf{y},\mathbf{u})=\left[\mathrm{sign}\left(\frac{\partial y_i}{\partial u_j}\right)\right],\ \begin{matrix} i=1,2; \\ j=1,2,3,4,5 \end{matrix}.$$

Настройка системы градиентного нейросетевого управления состоит из двух этапов [17].

На первом этапе решается задача робастного нейроуправления, которая заключается в поиске архитектуры сети MLP (числа слоёв сети, числа нейронов в скрытых слоях, типа функции активации в каждом слое), коэффициента шага градиентного метода η, определяющего скорость настройки параметров $\mathbf{W}$, коэффициента регуляризации λ, обеспечивающего устойчивость процесса настройки.

На первом этапе в результате имитационных исследований на основе математической модели на множестве возможных реализаций объекта управления (неонатального инкубатора) и прогнозируемых случайных возмущений предварительно выбирается архитектура сети MLP, настроечные параметры алгоритма η, λ, а также первоначальный вектор весовых коэффициентов $\mathbf{W}_0$.

На втором этапе настройка системы (рис. 2) осуществляется в процессе управления действующим объектом – неонатальным инкубатором в присутствии случайных возмущений с использованием данных, полученных на первом этапе.

В результате модельных исследований системы управления неонатальным инкубатором найдена структура нейронной сети MLP, включающая один внутренний слой, содержащий 50 нейронов. Во внутреннем и внешнем слоях использованы функции активации в виде гиперболического тангенса, определены параметры настройки алгоритма: $\eta = 0{,}05$, $\lambda = 0{,}01$.

Проведенные многочисленные имитационные исследования показали высокую эффективность разработанного метода градиентного нейросетевого управления. Планируется практическая реализация метода градиентного нейросетевого управления в неонатальных инкубаторах с использованием мини-компьютера «Raspberry Pi 4B 4GB RAM» и языка программирования Python.

Заключение

Рассмотрены существующие подходы к управлению параметрами внутренней среды инкубатора.

Описана структура нейросетевой динамической системы, обеспечивающая высокоточное поддержание температуры и влажности в инкубаторе.

Предложен алгоритм нейросетевого управления, основанный на коррекции весовых коэффициентов с использованием метода градиентного управления и обратного распространения ошибки.

Список литературы

[1] Zermani M.A., Feki E., Mami A. Building simulation model of infant incubator system with decoupling predictive control, IRBM 35, 2014, pp. 189-201.

[2] Manley B. J., Doyle L. W., Davies M. W., Davis P.G. Fifty years in neonatology // J Paediatr Child Health, 2015, 51 (1).

[3] Travers C.P., Carlo W.A., Ambalavanan N. The Future of Outcome Prediction for Preterm Infants in the Neonatal ICU // Am J Respir Crit Care Med, 2022; 205(1), pp. 6-8. doi: 10.1164/rccm.202109-2188ED. PMID: 34710338; PMCID: PMC8865594.

[4] Webster J.G. Encyclopedia of medical devices & instrumentation. 2nd ed., vol. 4, 2006. P. 144-146.

[5] Hadj Ali J. El, Feki E., Mami A. Dynamic Matrix Control DMC using the Tuning Procedure based on First Order Plus Dead Time for Infant-Incubator // International Journal of Advanced Computer Science and Applications, vol. 10, №6, 2019, pp. 358-367.

[6] Hadj Ali J. El, Feki E., Zermani M.A., de Prada C., Mami A. Incubator system identification of humidity and temperature: Comparison between two identification environments // 9th International Renewable Energy Congress (IREC), Hammamet, Tunisia, 2018, pp. 1-6, doi: 10.1109/IREC.2018.8362529.

[7] Feki E., Zermani M.A., Mami A. GPC Temperature Control of A Simulation Model Infant-Incubator and Practice with Arduino Board // International Journal of Advanced Computer Science and Applications, vol. 8, №6, 2017, pp. 46-59.

[8] Zermani M.A., Feki E., Mami A. Self-tuning weighting factor to decoupling control for incubator system // International Journal of Information Technology, Control and Automation (IJITCA), vol.2, №3, 2012, pp. 67-83.

[9] Zermani M.A., Feki E., Mami A. GPC multivariable control applied to temperature and humidity neonate incubators // International Conference on Electrical Engineering and Software Applications, Hammamet, Tunisia, 2013, pp. 1-6, doi: 10.1109/ICEESA.2013.6578492.

[10] Zermani M.A., Feki E., Mami A. Decoupling multivariable GPC with reference observation and feed-forward compensation method. Case Study: Neonate incubator // International Journal of Computer Science Issues, vol. 9, Issue 4, № 3, 2012, ISSN (Online): 1694-0814, pp. 508-515.

[11] Feki E., Zermani M.A., Mami A. Decoupling Control Approach for Neonate Incubator System // International Journal of Computer Applications, vol. 47, №2, 2012, pp. 49-57.

[12] Zermani M.A., Feki E., Mami A. Building simulation model of infant-incubator system with decoupling predictive controller // IRBM, vol. 35, Issue 4, 2014, pp. 189-201.

[13] Zermani M.A., Feki E., Mami A. Application of Genetic Algorithms in identification and control of a new system humidification inside a newborn incubator // International Conference on Communications, Computing and Control Applications (CCCA), Hammamet, Tunisia, 2011, pp. 1-6, doi: 10.1109/CCCA.2011.6031225.

[14] Hadj Ali J. El, Feki E., Mami A. Tuning PID using particle swarm optimization for controlling temperature of the infant incubator // International Journal of Computer Science and Network Security, vol. 20 №3, 2020, pp. 174-182.

[15] Ben Ali R., Jaballah M., Aridhi E., Mami A. Design and FPGA-implementation of a PID controller for temperature control in a refrigeration system // Indian Journal of Science and Technology, 2018, vol. 11, pp. 1-14. doi: 10.17485/ijst/2018/v11i16/121762.

[16] Schiff S.J. Neural Control Engineering The Emerging Intersection between Control Theory and Neuroscience. The MIT Press; 1st edition (January 1, 2012), 384 p.

[17] Frolov S.V., Sindeev S.V., Korobov A.A., Potlov A.Yu. Combined Method of Neurocontrol for Nonlinear Non-Stationary Object // 2nd International Conference on Control Systems, Mathematical Modeling, Automation and Energy Efficiency (SUMMA), 2020, pp. 582–585, doi : 10.1109/SUMMA50634.2020.9280705

[18] Фомин В.Н., Фрадков А.Л., Якубович В.А. Адаптивное управление динамическими объектами. М.: Наука, Гл. ред. физ-мат литературы, 1981. 448 с.

[19] Bishop C.M. Pattern Recognition and Machine Learning 2nd (second) edition byBishop. Springer, 2nd (second) edition, 2007, 738 p.

Оценка применимости методов машинного обучения для выявления патологии внутренних органов человека по результатам биоэлектрографии

Ю. А. Шичкина[1], Р. Р. Фаткиева[2], А. Е. Сычев[3]
М С Прасад[4], Верма Шивани[4]
[1,2,3]*Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» им. В.И. Ульянова (Ленина)*
[4]*Университет Амити, Уттар-Прадеш, Индия*
[1]strange.y@mail.ru, [2]rikki2@yandex.ru, [3]the220th@gmail.com

Аннотация. **Рассмотрена возможность применения метода биоэлектрографии для обнаружения патологии внутренних органов. Сформированы наборы датасетов для машинного обучения на основе показаний ультразвуковой диагностики. Проанализированы методы машинного обучения с оценкой целесообразности их применения. Представлены результаты выявления патологии внутренних органов с использованием классификаторов: Decision tree; KNN; Logistic regression; Random forest; SVC; XGBoost.**

Ключевые слова: биоэлектрография, машинное обучение, ультразвуковая диагностика, патология внутренних органов, ГРВ-граммы

I. Введение

Современный рост мощности вычислительной техники позволяет применять математические модели в совокупности с физиологическими показателями человека. Это дает возможность разрабатывать и внедрять методы быстрого анализа состояний человека, одним из которых является получение и анализ ГРВ-грамм, основанный на биоэлектрографии [1]. Возможность применения такого подхода подтверждается исследованиями [1–14]. В работах [1–4] анализируется патология сердечно-сосудистой системы. В работе [2] показано, что динамика вариабельности сердечного ритма и биоэлектрографии меняется в зависимости от сезона. В исследовании [3] выявлено, что параметры ГРВ у больных артериальной гипертонией и здоровых испытуемых различаются (особенно это заметно на левой руке). В работе [4] наблюдалось поражение магистральных артерий головы на экстракраниальном уровне с использованием ГРВ грамм. Сформирована классификация пациентов на группы: здоровые; пациенты с выявленными стенозами церебральных артерий < 50 % диаметра сосуда или извитостями этих сосудов с локальным гемодинамическим сдвигом и пациенты с выявленными стенозами просвета сосудов >50 % или выраженными извитостями этих сосудов с гемодинамически значимым сдвигом. На основании ГРВ-грамм произведен поиск секторов, которые возможно использовать в дальнейшем для построения диагностических правил. Сделан вывод, что метод ГРВ-биоэлектрографии позволяет с достаточно высокой точностью диагностировать наличие и степень патологических изменений сосудов на экстракраниальном уровне.

Исследованию патологии органов дыхания посвящены работы [5, 12], в которой отмечалась взаимосвязь хронической обструктивной болезни лёгких 1–2 стадий и ГРВ-грамм. Структура и выраженность психовегетативных нарушений у больных выявлялась с помощью опросника Вейна и госпитальной шкалы тревоги и депрессии в [5]. На основании этих данных осуществлялась оценка корреляции между ГРВ-грамм и течением основного заболевания.

К отдельному направлению можно отнести оценку влияния метеофакторов на параметры биоэлектрограмм у пациентов [2, 6–7]. В работе [7] показано как меняется ГРВ-грамма в зависимости от гелиогеомагнитных факторов на производные параметры ГРВ-грамм. В исследовании [8] – влияние метода биологической обратной связи с использованием биоэлектрографии.

Методы биоэлектрографии применяются и в задачах оценке функционирования деятельности спортсменов [1, 9]. В [1] показано, что оценка ГРВ-грамм позволяет с достаточной точностью проводить экспресс-оценку параметров психофизиологического состояния спортсменов на всех этапах подготовки и участия в ответственных соревнованиях Выявлено, что происходит снижение площади свечения ГРВ-грамм, а также увеличение коэффициента активации в группе с низкими адаптационными возможностями. В работе показано, что ГРВ-граммы спортсменов в состоянии покоя являются относительно более структурированными по сравнению со здоровыми испытуемыми соответствующего возраста из контрольной группы. Обобщая указанные исследования, можно сказать, что метод ГРВ-биоэлектрографии целесообразно использовать в скрининговой оценке функционального состояния организма спортсменов-легкоатлетов. Оба исследования подтверждают предположения, что методы биоэлектрографии позволяют своевременно проводить коррекционные мероприятия, направленные на их оптимизацию, в том числе средствами психофизиологической и

Работа поддержана Министерством науки и высшего образования Российской Федерации Соглашением № 075-15-2022-291 о предоставлении гранта в виде субсидий из федерального бюджета на осуществление государственной поддержки создания и развития научного центра мирового уровня «Центр интегративной физиологии им. Павлова«. для медицины, высокотехнологичного здравоохранения и технологий повышения стрессоустойчивости»

психологической поддержки тренировочной и соревновательной деятельности.

Методы оценки устойчивости к стрессу рассмотрены в [11, 12].

Особенности биоэлектрографии у больных сахарным диабетом выявлены в [13, 14]. Установлено достоверное изменение ряда показателей газоразрядной визуализации у больных сахарным диабетом 1-го типа, что дает возможность применять метод в амбулаторных условиях для диагностики у пациентов с сахарным диабетом 1-ого типа [13], а в [14] для диагностики у пациентов с сахарным диабетом 2-ого типа.

Анализ полученных результатов исследований показал, что использование ГРВ-грамм пациентов, в сопоставлении с традиционными методами выявления патологии органов позволяет обучить исследуемую модель, для дальнейшего использования только результатов биоэлектрографии.

II. Выявление патологии внутренних органов человека по результатам биоэлектрографии

Для получения набора исходных данных использовались датасеты, сформированные методом биоэлектрографии, которые сопоставлялись, с результатами, полученными методами ультразвуковой диагностики. Информация собиралась с помощью снятия результатов биоэлектрографии с пальцев, помещенных в устройство Bio-Well, а также из результатов ультразвуковой диагностики органов человека, полученных из общего хранилища файлов с наблюдениями и заключениями по различным нарушениям. Это позволило выявить корреляцию патологии внутренних органов с результатами биоэлектрографии.

По результатам этого этапа было сформировано хранилище данных, в котором имеются более 4000 результатов ультразвуковой диагностики и хранилище по датасетам, содержащим данные биоэлектрографии. Однако систематизация полученных данных на практике столкнулась с проблемами интероперабельности и конвертации форматов, поскольку данные для обработки представлены в неудобном для последующей обработки формате. Так анализ отобранных результатов ультразвуковой диагностики выявил проблему, при которой в одном файле может содержаться несколько заключений по разным органам, а может быть несколько файлов, в которых хранятся результаты ультразвуковой диагностики разных систем исследуемого организма. В связи с этим для получения объединенного набора данных встала задача сбора всех исследований по каждому пациенту в отдельности. В связи чем, для автоматизации процесса сопоставления было разработано программное обеспечение, которое осуществляло перебор файлов с отбором необходимых данных. Комплекс разрабатываемого программного обеспечения представлен на рис. 1. Следующим этапом стало формирование обобщенного датасета, нацеленного на выборку заключений по необходимым органам, в виде сформированной таблицы, где каждому исследуемому сопоставляется заключение по каждому заболеванию в отдельности.

Рис. 1. Комплекс разработанного программного обеспечения

На основании полученной таблицы с помощью разработанного программного обеспечения и сформованного набора данных для каждого исследуемого на основе поставленных диагнозов или наблюдений выносится факт о наличии патологии исследуемого органа. Например, о наличии проблемы с желудочно-кишечным трактом и мочеполовой системой могут говорить следующие диагнозы: гепатомегалия, стеатогепатоз, гепатоспленомегалия, дискинезия желчевыводящих путей (ДЖВП), диффузные изменения структуры почек. И, если программное обеспечение встречает заключение: *«Эхографическая картина диффузных изменений структуры поджелудочной железы, гепатомегалия, расширение члс, микролиты левой почки»*, то формируется заключение о том, что у исследуемого предполагаются проблемы: с поджелудочной железой; увеличение печени, а также диффузные изменения структуры почек (почками в целом). По результатам работы программного обеспечения, на данном этапе формируется документ, в котором каждому пациенту ставится в соответствие предположение о наличии патологии с органом в виде, представленном на рис. 2, где 1 означает наличие патологии исследуемого органа, 0 – отсутствие патологии. Прочерк или темный столбец равнозначен отсутствие информации по данному органу во всех файлах результатов ультразвуковой диагностики, которые имеются для данного пациента.

Для валидации заключений, которые были сформированы программным обеспечением, привлекался врач-эксперт в области медицинской диагностики с целью проверки правильности выводов о наличии патологии органов. Это позволило сформировать итоговый датасет, по которому осуществлялось машинное обучение, и построить гисторгаммы распределения патологии по выбранным органам (пример гистограммы представлен на рис. 2). На полученных гистограммах представлено распределение количества здоровых (0), и имеющих патологию (1) исследуемого органа, а также количество пациентов, у которых отсутствуют данные о патологии по исследуемому органу (-).

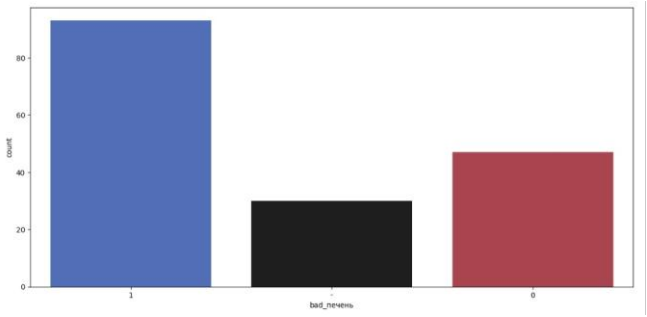

Рис. 2. Пример распределения лиц, имеющих патологию печени

Анализ полученных гистограмм, показал, что к наиболее часто встречающимся нарушениям можно отнести патологию таких органов, как: желчный пузырь; печень; поджелудочная железа; почки; селезенка; щитовидная железа. При этом анализ формы гистограмм свидетельствует о том, что в большинстве случаев для них отсутствует равномерное распределение и превалирует факт о наличии патологии органа, либо ее отсутствии. В связи с этим возникла необходимость использования разных подходов к классификации патологии, поэтому на этапе обучения модели были выбраны следующие классификаторы: Decision tree; KNN; Logistic regression; Random forest; SVC; XGBoost в двух вариантах: направленный на метрику f1; направленный метрику recall.

В этих условиях возникла задача поиска классификатора с наилучшими значениями предсказаний из представленных. Разделение XGBoost было выбрано в двух вариантах с целью обучения модели максимально точно предполагать патологию органа (целевая метрика – f1), либо обнаружение данных, относящихся к наименьшему классу (целевая метрика – recall). Для остальных классификаторов использовался GridSearch, позволяющий подобрать наилучшие параметры для каждого из классификаторов.

В процессе обучения задача обнаружения разделилась на 6 подзадач, в каждой из которых присутствовала бинарная классификация: патологии органов рассматривались отдельно друг от друга, т. е. результатом для каждого случая стала 1 или 0, где 1 – факт о патологии с органа и использовалось 4 подхода:

- данные оставлялись в первоначальном виде;
- данные для обучения дополнялись с помощью использования SMOTE;
- признаки стандартизировались с помощью StandardScaler;
- признаки стандартизировались, а данные для обучения еще и дополнялись с помощью SMOTE.

Каждая модель для каждого исследуемого органа рассматривался отдельно, а после проводилось сравнение, для выбора определенного классификатора, демонстрирующего наилучшие результаты.

III. Результаты практического применения

По результатам обучения и предсказывании фактов о проблеме с тем или иным органом получились следующие результаты. Для желчного пузыря наилучшим классификатором оказался RandomForest, данные для обучения проходили через дополнение с помощью SMOTE. Матрица ошибок и метрики для него представлены на рис. 3.

```
[[ 9  5]
 [10 23]]
```

	precision	recall	f1-score	support
0	0.47	0.64	0.55	14
1	0.82	0.70	0.75	33
accuracy			0.68	47
macro avg	0.65	0.67	0.65	47
weighted avg	0.72	0.68	0.69	47

Рис. 3. Результаты применения модели RandomForest для выявления патологии желчного пузыря

Для выявления патологии печени целесообразно применять как логистическую регрессию, так и XGBoost, у которого целевая метрика recall. Для обеих моделей данные для обучения проходили через дополнение с помощью SMOTE. Матрица ошибок и метрики показаны на рис. 4 и 5.

```
[[ 7  4]
 [12 24]]
```

	precision	recall	f1-score	support
0	0.37	0.64	0.47	11
1	0.86	0.67	0.75	36
accuracy			0.66	47
macro avg	0.61	0.65	0.61	47
weighted avg	0.74	0.66	0.68	47

Рис. 4. Результаты применения логистической регрессии для выявления патологии печени

```
[[ 9  2]
 [15 21]]
```

	precision	recall	f1-score	support
0	0.38	0.82	0.51	11
1	0.91	0.58	0.71	36
accuracy			0.64	47
macro avg	0.64	0.70	0.61	47
weighted avg	0.79	0.64	0.67	47

Рис. 5. Результаты применения модели XGBoost для выявления патологии печени

Для поджелудочной железы наилучшие результаты показали модели логистической регрессии и случайного леса. Для этих классификаторов матрица ошибок и метрики отображены на рис. 6.

```
[[ 6  3]
 [10 28]]
```

	precision	recall	f1-score	support
0	0.38	0.67	0.48	9
1	0.90	0.74	0.81	38
accuracy			0.72	47
macro avg	0.64	0.70	0.65	47
weighted avg	0.80	0.72	0.75	47

Рис. 6. Результаты применения логистической регрессии и случайного леса для выявления патологии поджелудочной железы

Для выявления патологии почек лучший результат продемонстрировал классификатор Decision Tree, результат которого представлен на рис. 7.

```
[[ 3  4]
 [13 27]]
```

	precision	recall	f1-score	support
0	0.19	0.43	0.26	7
1	0.87	0.68	0.76	40
accuracy			0.64	47
macro avg	0.53	0.55	0.51	47
weighted avg	0.77	0.64	0.69	47

Рис. 7. Результаты применения классификатора Decision Tree для выявления патологии почек

Однако применение указанных методов в целях обнаружения патологии селезенки показало, что ни один из классификаторов не смог правильно справиться со своей задачей, поскольку результаты сильно отличаются от упомянутых выше. Наилучшие результаты в этом

классе были получены при применении моделей случайного леса и логистической регрессии, они представлены на рис. 8.

```
[[41  1]
 [ 5  0]]
              precision    recall  f1-score   support

           0       0.89      0.98      0.93        42
           1       0.00      0.00      0.00         5

    accuracy                           0.87        47
   macro avg       0.45      0.49      0.47        47
weighted avg       0.80      0.87      0.83        47
```

Рис. 8. Результаты применения логистической регрессии и случайного леса для выявления патологии селезенки

Для определения патологии щитовидной железы наилучшим классификатором оказался KNN, который продемонстрировал результат, представленный на рис. 9.

```
[[ 5  2]
 [19 20]]
              precision    recall  f1-score   support

           0       0.21      0.71      0.32         7
           1       0.91      0.51      0.66        39

    accuracy                           0.54        46
   macro avg       0.56      0.61      0.49        46
weighted avg       0.80      0.54      0.61        46
```

Рис. 9. Результаты применения модели KNN для выявления патологии щитовидной железы

Подводя итог исследования, можно выделить следующие особенности применения перечисленных методов:

- для желчного пузыря наилучшим оказался RandomForest, который правильно распознавал результат с точностью в 68 %;
- для печени лучшими оказались логистическая регрессия и XGBoost с целевой метрикой recall, которые показали точность в 66 %, практически с равной степенью обнаружения как патологии, так и нормального функционирования органа;
- для поджелудочной железы точность в 72 % показали логистическая регрессия и случайный лес, наименьший процент распознавания одного из классов – 67 %;
- для почек наилучший результат – точность предсказаний 64 %, однако здоровый орган правильно определялся с точностью менее 50 %;
- селезенка – орган, корректно предсказывать факт болезни которого оказалось невозможным: лучшая точность хоть и составляла 87 %, таковой она была за счет преобладания одного из классов;
- выбранный классификатор для щитовидной железы – KNN – наилучшим образом определял здоровый орган (71 %), однако общая точность предсказаний близка к 50 % – 54 %. Процент верно определенной больной щитовидной железы составляет всего 51 %.

Анализируя полученные результаты, можно сказать, что процент ошибок меньше в тех моделях, где распределение количества больных и здоровых людей приближается к нормальному. Расширение метода с дальнейшим применением нейронных сетей возможно, но затруднено трудоёмкостью процесса, при равных по сравнению с моделями машинного обучения результатах.

IV. Заключение

К дальнейшему направлению исследований целесообразно отнести расширение классов моделей машинного обучения относительно систем организма, к которым эти методы возможно применять. Отдельно возможно рассмотреть комбинацию методов для более точного выявления той или иной патологии.

Список литературы

[1] Короткова А.К., Коротков К.Г., Шелков О.М. Метод компьютерной биоэлектрографии в подготовке спортсменов олимпийского резерва // Адаптивная физическая культура. 2013. № 1(53). С. 26-27.

[2] Ботоева Н.К., Беляева В.А., Хетагурова Л.Г., Гонобоблева Т.Н. Сезонная динамика нелинейных показателей вариабельности сердечного ритма и ГРВ-биоэлектрограмм у лиц, проживающих в предгорной зоне Северной Осетии // Вестник новых медицинских технологий. 2013. Т. 20, № 2. С. 417-422.

[3] Коробка И.Е., Яковлева Е.Г., Коротков К.Г. Возможности метода ГРВ биоэлектрографии в диагностике активности правого полушария мозга у больных артериальной гипертонией // Вестник новых медицинских технологий. 2013. Т. 20, № 1. С. 125-129.

[4] Александрова Е.В., Зарубина Т.В., Зубкова А.В. Биоэлектрографический подход к выявлению пациентов с различными поражениями магистральных артерий головы на экстракраниальном уровне // Вестник новых медицинских технологий. 2011. Т. 18, № 3. С. 94-96.

[5] Овсянников Е.С. Газоразрядная визуализация как инструмент оценки психосоматическогостатуса пциентов с хронической обструктивной болезнью легких // Научно-медицинский вестник Центрального Черноземья. 2012. № 49. С. 61-65.

[6] Беляева В.А., Ботоева Н.К. Влияние метеофакторов на параметры биоэлектрограмм у здоровых лиц // Современные проблемы науки и образования. 2012. № 1. С. 208.

[7] Беляева В.А., Ботоева Н.К. Оценка влияния гелиогеомагнитных факторов на здоровых лиц методом биоэлектрографии. 2013. Т. 12, № 3. С. 666-674.

[8] Соловьевская Н.Л. Оценка эффектов БОС-терапии с применением метода биоэлектрографии в курсе коррекции психофизиологического состояния жителей Арктики // Вестник Уральской медицинской академической науки. 2018. Т. 15, № 2. С. 324-333. DOI 10.22138/2500-0918-2018-15-2-324-333.

[9] Ботоева Н.К., Беляева В.А., Лунева О.Г., Краснобаев А.Ф. Метод ГРВ-биоэлектрографии в оценке адаптационных резервов организма спортсменов и эффективности хронокоррекции доклинических нарушений их здоровья // Владикавказский медико-биологический вестник. 2012. Т. 14, № 22. С. 24-31.

[10] Столов И.И. Метод газоразрядной визуализации биоэлектрографии и его программное обеспечение для спорта // Вестник спортивной науки. 2006. № 4. С. 34-36.

[11] Немых В.Н., Пашков А.Н., Суховеева Сравнительная оценка устойчивости к стрессу девушек и юношей в группе иностранных учащихся с помощью показателей ГРВ биоэлектрографии кожных поверхностей четвёртых пальцев рук // Научно-медицинский вестник Центрального Черноземья. 2015. № 60. С. 132-136.

[12] Вахмистров В.В., Тишкова Ю.Ю. Оценка уровня психофизиологического стресса горноспасателей МЧС России при помощи метода газоразрядной визуализации биоэлектрографии // Научно-технический прогресс: актуальные и перспективные направления будущего: Сб. материалов IV Международной научно-практ. Конф., Кемерово, 30 ноября 2016 года / Западно-Сибирский научный центр. Том I. Кемерово, 2016. С. 117-119.

[13] Мячина О.В, Зуйкова А.А., Пашков А.Н., Пичужкина Н.М. Исследование конденсата выдыхаемого воздуха методом биоэлектрографии у пациентов с сахарным диабетом 1 типа // Вестник новых медицинских технологий. 2014. Т. 21, № 1. С. 29-32. DOI 10.12737/3306.

[14] Мячина О.В., Зуйкова А.А., Пашков А.Н. Особенности грв биоэлектрографии секретов больших слюнных желез у больных сахарным диабетом // Успехи современного естествознания. 2012. № 7. С. 46-49.

Возможность визуализации трехмерно звука для оценки локализации его источника

Димитриос Палогианнидис
Кафедра биотехнических систем
Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» им. В.И. Ульянова (Ленина)
dimitris.palogiannidis@gmail.com

***Аннотация*. Слух является вторым чувством, на которое люди полагаются больше всего, после зрения. Что происходит, однако, когда кто-то слабовидящий и вынужден полагаться на него в своих повседневных задачах? Люди тренируются использовать эхолокацию, метод, используемый многими млекопитающими, для оценки расстояния до источника звука. Математический подход к локализации звука обеспечивается передаточной функцией, связанной с головой (HRTF), которая позволяет всем людям оценить местоположение источника звука в окружающей их среде. В этой статье описывается метод трехмерного анализа звука с помощью двухмерной визуализации с использованием Python для оценки производительности HRTF на человека во время реабилитации.**

Ключевые слова: 3D-звук; HRIR; HRTF; Python; нарушение зрения; реабилитация; оценка расстояния; локализация звука

I. Введение

Медицинская оценка нарушений зрения является важнейшим шагом в процессе реабилитации людей с такими нарушениями, которые не поддаются медикаментозному лечению. После постановки диагноза важно, чтобы процесс реабилитации начался немедленно. Обычно это достигается за счет использования других органов чувств, на которые полагаются люди, и особенно слуха. Это означает, что процесс реабилитации включает в себя оценку множества аспектов, таких как когнитивный статус, ориентация и слуховые способности каждого человека.

Ориентация и слуховые способности (или, другими словами, локализация звука) могут быть оценены с помощью функции передачи, связанной с головой (HRTF), для пространственной привязки любого звука в любом месте окружения пользователя в целях перекрестной проверки с учетом индивидуальных возможностей.

II. Физиология, лежащая в основе HRTF

A. Основные принципы локализации звука

HRTF – это врожденная способность, которой обладают люди, воспринимать направление, с которого звук доходит до их ушей. Этот когнитивный процесс включает в себя анализ временных различий в поступлении звука между двумя ушами, которые впоследствии коррелируются с θ. По сути, на звуки, достигающие слухового прохода, влияет уникальная морфология человеческой головы и туловища, а также сложные структуры наружного уха, известные как ушная раковина. Ушная раковина вызывает микроэхо во входящем звуковом сигнале, в то время как трехмерная кривизна головы изгибает или рассеивает звуковые волны [1–3]. Следовательно, барабанная перепонка получает сложный набор сигналов, предоставляя мозгу ценные подсказки для устранения неоднозначности θ. По сути, головка, охватывающая ушную раковину, функционирует как фильтр, который изменяет акустические сигналы в зависимости от угла их падения, называемый HRTF в частотной области. Понимание HRTF для каждого θ открывает новые возможности в пространственной акустике.

Практически применение знаний HRTF открывает различные возможности в пространственной акустике. Используя наушники, оснащенные левым и правым HRTF, соответствующими желаемому θ, можно обрабатывать обычные звуки, и результирующие два сигнала воспроизводятся через соответствующие наушники [4, 5]. В результате мозг воспринимает этот синтезированный звук как направленный, исходящий под углом θ относительно головы.

B. Классификация HRTF

HRTF подразделяется на две различные категории: ближнее поле и дальнее поле. HRTF ближнего поля относится к измерениям HRTF, полученным в непосредственной близости от головы слушателя, обычно в пределах нескольких сантиметров. Эта характеристика отражает непосредственное акустическое воздействие, охватывающее уши слушателя, включая тонкие нюансы, вытекающие из анатомических структур каждого человека. Получение измерений HRTF в ближнем поле облегчает тщательный поиск пространственной информации, что делает его особенно актуальным для точной локализации звука и персонализированных слуховых взаимодействий.

Напротив, HRTF дальнего поля означает измерения HRTF, проводимые на расстоянии от слушателя, обычно проводимые в контролируемых условиях, таких как специализированные акустические лаборатории или безэховые камеры. В условиях дальнего поля зрения слуховое воздействие морфологии тела и головы слушателя на распространение звука уменьшается. Вместо этого акцент смещается в сторону улавливания общих акустических характеристик, присущих передаточной функции, связанной с головой слушателя, включая спектральную окраску и всесторонние сигналы направления. Более того, в то время как звуки дальнего поля представляют собой почти параллельные лучи, когда они достигают двух ушей, чего нельзя сказать о ближнем поле, где они пересекаются.

Этим ограничением можно пренебречь при использовании наушников, поскольку путь передачи звука (воздух) между наушником и самим слуховым проходом является максимально коротким. Само по себе это означает, что морфология туловища и головы также не учитывается при восприятии звука; следовательно, единственным аспектом, влияющим на восприятие звука, является когнитивный статус человека и качество драйверов наушников.

Двумя параметрами, влияющими на местоположение звука в окружающей среде, являются координаты азимута и высоты, которые указывают степень распространения звука в горизонтальной и вертикальной плоскостях в зависимости от пользователя. Азимут и угол возвышения можно визуализировать на рис. 1 и 2 соответственно.

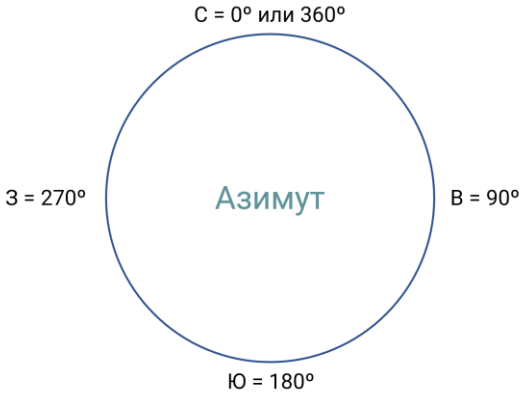

Рис. 1. Схематическое представление азимутальных градусов вокруг человека. Местоположение объекта перед человеком находится на 0º или 360º, справа на 90º, позади него на 180º и слева от него на 270º

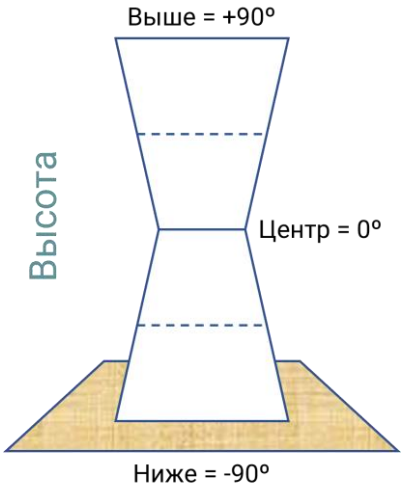

Рис. 2. Схематическое изображение степеней возвышения над и под отдельным

III. Материалы и методы

A. *Выбранный набор данных*

При этом используется набор данных KEMAR [6], собранный в 1994 году в безэховой камере Массачусетского технологического института. Набор данных KEMAR представляет собой набор измерений HRTF на манекене головы, называемом KEMAR. Они состоят из импульсных сигналов левого и правого ушей от громкоговорителя определенной марки, установленного по периметру манекена в 1,4 метра. Частота дискретизации была установлена на уровне 44,1 кГц (больше верхнего предела возможностей человеческого слуха в 20 кГц), так что соблюдаются условия теоремы Найквиста, где в общей сложности было отобрано 710 различных позиций. Перепады высот варьируются от -40º до +90º.

B. *Выбор языка программирования и библиотек*

Выбранным языком программирования был Python. Python обладает бесконечными возможностями для обработки данных и манипулирования ими, включая использование HRTF и пространственное распределение звука. Однако для создания кода был использован набор библиотек.

Numpy [7] – это библиотека с открытым исходным кодом, которая позволяет обрабатывать большие многомерные массивы и матрицы, наряду с большим набором высокоуровневых математических функций для работы с этими массивами. Среди прочего, он предлагает комплексные математические функции, генераторы случайных чисел, процедуры линейной алгебры и преобразования Фурье. Pyplot [8] – это библиотека, которая заставляет python вести себя как MATLAB. Модуль Matplotlib [9] позволяет создавать фигуры, области построения, графики, надписи и другие. Soundfile [10] – это аудиотека, основанная на Libsndfile, CFFI и Numpy, используемая для чтения и записи звуковых файлов. Librosa [11] – это пакет python для анализа музыки и аудио. Он предоставляет строительные блоки, необходимые для создания систем поиска музыкальной информации IPython [12] предоставляет пользователю интерактивные оболочки в графическом интерфейсе.

C. *Используемые звуки*

Предполагая, что пациенты имеют хороший когнитивный статус, наш подход поддерживает использование различных звуков для оценки возможностей пространственной ориентации. Начиная с простого «звукового сигнала», мы можем затем перейти к использованию звуков, встречающихся в повседневных ситуациях, таких как записи собачьего лая, автомобильных гудков или игр детей, как способ имитации чьих-то повседневных раздражителей.

IV. Структура кода

После загрузки набора данных KEMAR и различных звуков был указан исходный каталог для обоих. Набор данных KEMAR был отсортирован в целях повторяемости, и был выбран случайный файл с повышением 0. Используя библиотеку звуковых файлов, были сгенерированы Импульсные Отклики, Связанные С Головой (HRIR). Частота дискретизации составляла 44,1 кГц при размерах 128*2, поскольку HRIR имеет короткую длительность и является двухканальным (представляющим каждое ухо).

Визуализация временной области может быть достигнута сразу с помощью графика HRIR, показанного на рис. 3, который демонстрирует амплитуду HRIR для заданных координат. Правое ухо воспринимает большую амплитуду, чем левое ухо, что ожидается из-за расположения звука.

Визуализацию расположения звука можно увидеть на рис. 4, где звук расположен под углом 125º, измеренным от передней части пользователя, что означает, что звук расположен справа и сзади от уровня уха пользователя.

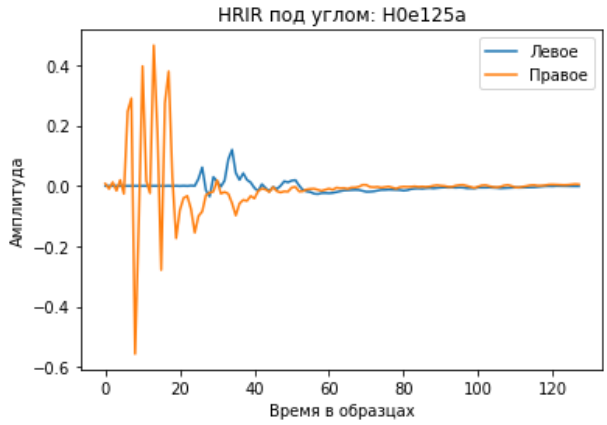

Рис. 3. Пример 2D-графика HRIR на высоте, равной 0o, и под углом, равным 125o, показывающий амплитуду звука с течением времени для каждого года (канала). Энергию, получаемую каждым ухом, можно визуализировать. Из-за расположения источника правое ухо получает больше энергии, чем левое, и в то же время полученная энергия достигает правого уха раньше, чем левого

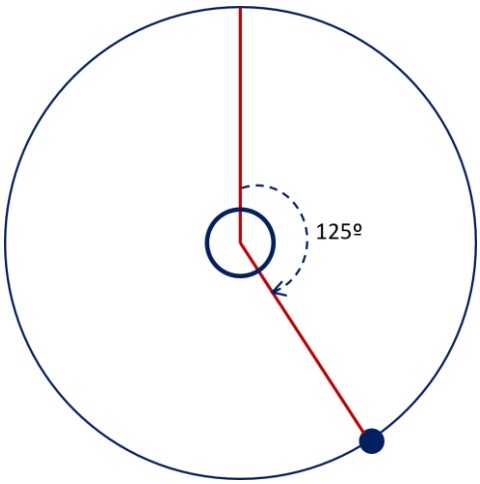

Рис. 4. Визуализация местоположения звука (заполненный круг по периметру большего круга) под углом 125° по отношению к пользователю (центральный круг)

Чтобы визуализировать звук в частотной области, необходимо было выполнить еще несколько шагов. HRTF произошел в результате Неравномерного Быстрого Преобразования Фурье (NFFT) HRIR. Используя Numpy, можно было бы оценить точную величину HRTF, которая является логарифмическим выражением HRIR. HRTF для тех же координат можно визуализировать на рис. 5, демонстрируя величину HRTF для каждого уха. Опять же, правое ухо получило звук большей амплитуды, находясь ближе к источнику.

Когда HRIR и HRTF были рассчитаны и визуально проверены, мы могли приступить к выбору источника звука, который мы хотели распределить по пространству. Используемые аудиоисточники имели частоту дискретизации 48 кГц, которая отличалась от частоты дискретизации HRIR, в то время как его размеры составляли 1494144*2 (размеры могут варьироваться в зависимости от продолжительности используемого звука). Подобно HRIR, аудиоисточники также являются двухканальными. Потенциально это может стать препятствием, поскольку требуемым результатом было бы восприятие звука как монофонического, а не двойного. Причина этого заключается в том, что локализация звука намного эффективнее, если используется только один канал (моно) и он размещен вокруг пользователя. Следовательно, исходные звуки были переведены из стерео в моно путем усреднения значений обоих каналов.

Поскольку частоты дискретизации не совпадали, мы приступили к повторной выборке HRIR с использованием Librosa до конечного массива 140*2. Соответствующая частота дискретизации HRIR и исходных файлов затем может быть сведена в один файл, который включает в себя всю информацию о звуке и пространстве. И последнее, но не менее важное: был сгенерирован звуковой файл для визуальной проверки исходного звука с помощью информации о пространственности и сопоставления ее с сгенерированными графиками.

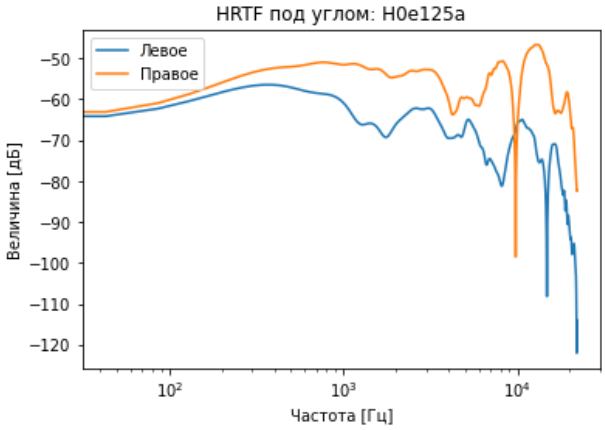

Рис. 5. Пример 2D-графика HRTF при высоте, равной 0o, и угле наклона, равном 125o, показывающий величину звука с течением времени для каждого года (канала). Из-за расположения источника правое ухо получает больше энергии, чем левое. Существует также возможность качественной оценки вариаций частоты приема между каждым ухом

V. Заключение

Исследование предоставило нам визуализацию поведения звука, когда он достигает наших ушей с искусственно созданного заданного направления. Код был сконструирован таким образом, чтобы была обеспечена повторяемость. Все различные координаты азимута и высоты могут быть проверены по желанию путем индексации различных файлов HRIR. Сгенерированный звуковой файл, воспроизводящий местоположение звука, был убедительным.

Список литературы

[1] Brown C.P., Duda R.O. An efficient HRTF model for 3-D sound // Proceedings of 1997 Workshop on Applications of Signal Processing to Audio and Acoustics. New Paltz, NY, USA: IEEE, 1997. P. 4.

[2] Gardner W.G., Martin K.D. HRTF measurements of a KEMAR // The Journal of the Acoustical Society of America. Acoustical Society of America, 1995. Vol. 97, № 6. P. 3907–3908.

[3] Hu H. et al. HRTF personalization based on artificial neural network in individual virtual auditory space // Applied Acoustics. 2008. Vol. 69, № 2. P. 163–172.

[4] Goodwin M., Jot J.-M. Binaural 3-D audio rendering based on spatial audio scene coding. 2007. Vol. 3. P. 1282–1293.

[5] Zotkin D., Duraiswami R., Davis L. Rendering Localized Spatial Audio in a Virtual Auditory Space // Multimedia, IEEE Transactions on. 2004. Vol. 6. P. 553–564.

[6] HRTF Measurements of a KEMAR Dummy-Head Microphone [Electronic resource]. URL: https://sound.media.mit.edu/resources/KEMAR.html (accessed: 12.01.2023).

[7] NumPy [Electronic resource]. URL: https://numpy.org/ (accessed: 13.01.2023).

[8] Pyplot tutorial – Matplotlib 3.7.1 documentation [Electronic resource]. URL: https://matplotlib.org/stable/tutorials/introductory/pyplot.html (accessed: 09.03.2023).

[9] Matplotlib – Visualization with Python [Electronic resource]. URL: https://matplotlib.org/ (accessed: 13.01.2023).

[10] python-soundfile – python-soundfile 0.11.0 documentation [Electronic resource]. URL: https://python-soundfile.readthedocs.io/en/0.11.0/ (accessed: 13.01.2023).

[11] librosa – librosa 0.9.2 documentation [Electronic resource]. URL: https://librosa.org/doc/latest/index.html (accessed: 13.01.2023).

[12] Jupyter and the future of IPython – IPython [Electronic resource]. URL: https://ipython.org/ (accessed: 13.01.2023).

Анализ сообщений в социальных сетях методами искусственного интеллекта

А. М. Лопушанский, Я. А. Бекенева
Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» им. В.И. Ульянова (Ленина)
sashalopy@mail.ru, yabekeneva@etu.ru

***Аннотация*. В настоящее время социальные сети представляют собой мощный источник информации. В различных сообществах публикуются новости, размещаются анонсы событий, а пользователи делятся мнениями и рекомендациями. Различные события, имеющие привязку к местности, упоминаются в районных сообществах. Анализ активности пользователей, содержание их сообщений и указание на возможные чрезвычайные ситуации представляет большой интерес для исследования не только паттернов взаимодействия, но и выявления возможных нештатных ситуаций в определенных локациях.**

Ключевые слова: социальные сети, анализ сообщений, нейронная сеть, чрезвычайные ситуации

I. Введение

Социальные сети могут включать в себя различные элементы, такие как профили пользователей, механизмы просмотра постов других пользователей, инструменты для обмена сообщений, публикации контента, объединения в группы. Соцсети могут иметь различные формы и направленность.

Для выявления нештатных ситуаций методами обработки естественного языка выгоднее использовать социальные сети, где преобладает текстовый контент. Далее следует обратить внимание, в каких социальных сетях больше активных пользователей, и где они более склонны создавать записи с новостями и публично обсуждать текущие события.

Анализ данных из социальных сетей – это в первую очередь обработка большого объема неформализованных текстовых данных. Для этого используются методы NLP (англ. Natural Language Processing – Обработка Естественного Языка). Рассмотрим релевантные статьи, описывающие подход к обработке больших объемов текста.

Перед извлечением какой-либо информации из постов или комментариев в социальных сетях требуется провести предобработку текста. В работе [1] описывается простейший порядок действий при подготовке текста к извлечению информации. Описанные алгоритмы предобработки универсальны и могут применяться, как для работы с английским языком, так и с русским, но при работе со вторым требуется особое внимание в силу многообразия инструментов словообразования в языке. Особенности морфологического анализа текста именно на русском языке описаны в статье [2]. В результате проведения опытов, было установлено, что многие существующие инструменты показывают достаточно высокую точность разметки. Различие между анализаторами заключается в точности определения отдельных частей речи. Все инструменты показывают высокую точность в определении таких частей речи как существительное, глагол или местоимение, но, например, при разметке прилагательных результаты существенно различаются.

Большинство социальных сетей позволяют оставлять комментарии под размещенными постами. Информация, полученная из комментариев пользователей, может быть так же важна, как и содержание самого поста. Похожим образом извлекается информация из отзывов к товарам. В статье [3] описываются способы выявления актуальной информации при оценке приложений отзывами. В статье показывают, что из массива отзывов возможно извлечь основные требования пользователей к приложению, а также возможно классифицировать отзывы, ориентируясь на их содержание.

В публикации [4] проводится сравнение функций ранжирования TF-IDF – Частота термина – обратная частота документа, и BM25 – функция, использующая схожий с первой подход. В работе были выделены ключевые слова для различных классов записей в социальной сети Twitter, а затем применены обе функции для выделения ключевых слов в тестовых данных. Этот подход применим не только к большим документам, но и к записям, таким как посты в Twitter, соответственно, его можно применять и в данной работе, независимо от выбранной соцсети и объема анализируемых в ней сообщений.

Одного анализа текста может быть недостаточно – для выявления событий и нештатных ситуаций может потребоваться иной подход, использующий для анализа не только текстовые данные, но и метаинформацию о постах и комментариях. Статья [5] описывает методику выявления событий, обсуждаемых в социальной сети Twitter. Подход, предложенный в статье, предполагает использование информации о географическом положении, опубликовавшего пост человека. Для одной географической зоны определяется закономерность времени и частоты публикации записей, таким образом, при происшествии какого-либо события ожидается необычный всплеск частоты постов в нехарактерное для них время или превышение ежедневной нормы количества постов. Также в работе предлагается проведение кластеризации обрабатываемых записей, это позволяет решить сразу две проблемы: если в кластере оказывается количество записей выше заданного порога, можно автоматически определить наличие какого-либо события, более того кластеризация позволяет отделить друг от друга записи о разных событиях, происходящих в одной области.

Работа выполнена при поддержке Гранта Президента Российской Федерации МК-918.2022.1.6.

II. Описание подхода и эксперименты

Перед тем, как разрабатывать модель нейронной сети, требуется предобработка данных. Для обучения модели будут использоваться только тексты сообщений и метки с классом сообщения. Для того, чтобы подготовить сообщения к передаче на вход нейронной сети, нужно очистить текст от знаков препинания, эмодзи, специальных символов, а так же, так как посты могут содержать ссылки на сторонние сайты, избавиться от любых ссылок в тексте.

После удаления всего шума из входных данных, требуется представить их в виде удобном, для обработки нейросетью.

Самый простой способ определить наличие события в потоке – найти внезапные выбросы в данных, например, данные поступают определенной частотой, согласно текущему тренду, сезонности (в случае с постами в соцсетях – смена дня и ночи), но некоторые данные не вписываются в общую модель – это аномалия, и она может оказаться событием.

Чтобы избавиться от единичных выбросов, можно анализировать не сами данные, а скользящее среднее по ним. Таким образом, единичные выбросы будут усреднены, и не будут оказывать сильного влияния на результат анализа, но особо крупные выбросы, а также продолжительные изменения останутся заметны.

В качестве метрики, по которой возможно определить наличие можно использовать количество отправленных сообщений за определенный промежуток времени. Значение будет колебаться со временем, так что днем обычно сообщений больше, чем ночью. При этом в случае происшествия как ночью, так и днем ожидается видимый рост числа сообщений. Недостаток такой метрики – невозможность определить причину роста количества сообщений.

За еще одну метрику возможно взять количество сообщений, распознанных разработанной ранее нейронной сетью. Ожидается, что в случае катастрофы, количество сообщений о ней резко возрастет. Тем не менее, рост сообщений о происшествиях может быть связан с общим ростом количества постов. Таким образом, с ростом количества сообщений ожидается рост количества сообщений по каждой тематике, в том числе о каких-либо несчастных случаях. Однако, на рост числа подобных сообщений все равно стоит обратить внимание, так как они могут нести в себе ценную информацию, о том, что происходит в данный момент.

Дополнительный способ определить, что что-то случилось – заметное изменения тона сообщений в течение короткого промежутка времени. Узнать тон сообщений можно, проведя сентиментальный анализ текста. В результате анализа сообщения можно получить рейтинг от -1 до 1, где -1 – негативный тон сообщения, 1 – позитивный тон, 0 – нейтральное сообщение. В случае катастрофы ожидается падение числа позитивных сообщений, по которому возможно определить период времени, когда началось изменение тона.

Используя описанные выше методы вместе, можно обнаружить наличие происшествия на наборе данных с сообщениями.

С целью хранения записей и информации о них должна быть спроектирована и разработана база данных. Сохраненные записи требуется обработать с целью извлечения из них информации. Чтобы избежать многократной обработки одних и тех же записей, записи следует обработать сразу после сохранения в базу данных. С целью нахождения связанных записей, из каждого сохраненного локально поста будут извлекаться именованные сущности – ключевые слова – имена, названия мест, которые могут связывать несколько записей, посвященных одному и тому же происшествию, между собой. Извлеченные сущности следует так же хранить в разработанной базе данных.

Основным действием пользователя разрабатываемой программы является поиск интересующей его записи, с помощью графического интерфейса приложения. После этого предполагается, что пользователь запросит отметку на карте с расположением происшествия в выбранной записи.

Основная идея предлагаемого подхода заключается в использовании NER (англ. Named Entity Recognition – Распознавание именованных сущностей). NER позволяет выделить в тексте слова или словосочетания, описывающие имена, адреса, названия организаций, даты или денежные значения. Выделив в тексте записи группы локацию происшествия, ее можно нанести на карту, используя методы геокодирования. Геокодирование – процесс преобразования адреса локации в географические координаты. Так, информацию об аварии на дороге можно разместить на карте, используя только запись в интернете.

Для размещения мест происшествия, описываемых в записях, на карте была разработана программа, которая осуществляет сбор записей из заданного сообщества и осуществляет обработку записей. В каждой записи с помощью NER выделяются сущности, каждой из которых назначается тип – имя, организация или локация, среди них выбираются только локации, затем выделенная локация преобразуется в координаты и наносится на карту.

Преимущество выделения сущностей в записях – возможность группировать несколько публикаций, описывающих одно место. Так можно выявлять проблемные места, где часто происходят аварии или находить последовательное описание событий, происходящих в одном месте. Сгруппируем записи, где описываются дорожно-транспортные происшествия на КАД.

Чтобы облегчить поиск выбросов на наборе данных, автоматически отметим выбросы на графике с помощью алгоритма кластеризации k-means. Точки, не относящиеся к определенным кластерам, являются аномальными. При кластеризации аномалии отличаются от точек, принадлежащим кластерам наиболее удаленным расстоянием от центра кластера. Отметим, таким образом, на графике точки, являющиеся аномальными. Отмеченные периоды времени можно считать потенциально особыми и проводить для них дальнейший частотный анализ, с целью выявления причины увеличения числа сообщений. На рис. 1 на графике частоты сообщений отмечены особые точки с использованием алгоритма k-means.

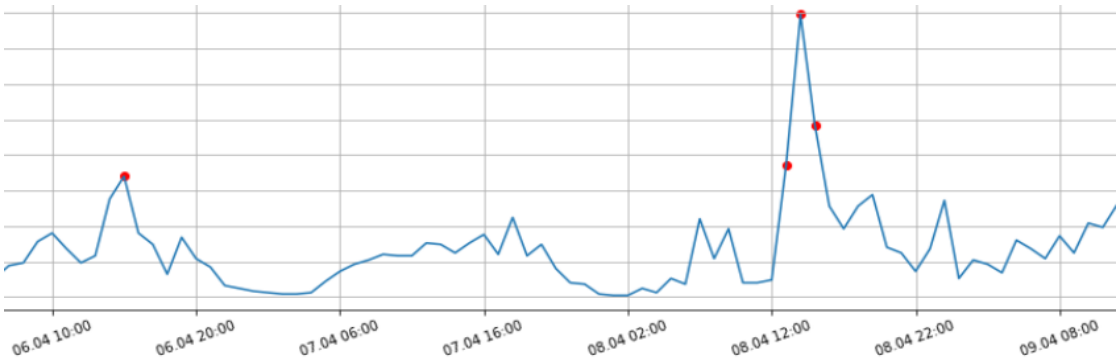

Рис. 1. Статистика постов, содержащих упоминание КАД

На рис. 1 изображена статистика записей в сообществе «ДТП и ЧП | Санкт-Петербург | Питер Онлайн | СПб» за одну неделю. Синим цветом отмечены показатели всех записей в сообществе, красные точки – записи, содержащие упоминание КАД. КАД, кольцевая автомобильная дорога, имеет протяженность около 150 километров и окружает город со всех сторон. Трафик на этой дороге составляет до 240 тысяч автомобилей в сутки. Следовательно, упоминания происшествий производятся почти каждый день.

На рисунке видно, что период времени, в который произошел наибольший выброс числа сообщений, помечен несколько раз. В то же время, аномальным был помечен и промежуток времени, в который было незначительное увеличение числа сообщений. Чтобы искать аномалии, при этом сглаживая эффект сезонности данных – смену числа сообщений вместе со сменой дня и ночи, сгладим данные. Сгладить данные, оставив возможность для обнаружения больших выбросов, можно с помощью вычисления скользящего среднего. Если рассчитывать среднее значение за увеличенный промежуток времени, можно избежать пометки небольших выбросов, как аномалий, при этом обнаруживать серьезные выбросы. Пример поиска аномалий на тех же данных с применением скользящего среднего приведен на рис. 2.

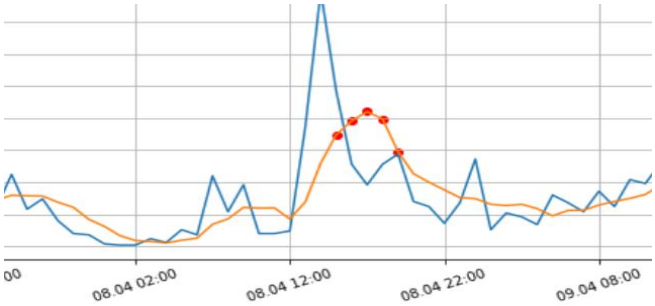

Рис. 2. Поиск аномальных точек на графике частоты сообщений

После открытия записи в программе, есть возможность примерно отобразить ее на карте. Функция отметки происшествия на карте будет более полезной при описании в записи более конкретного адреса происшествия, а не только района. Лучший способ найти большое количество записей, в которых регулярно описываются нештатные ситуации – анализ постов в группах, посвященным ДТП в определенных городах. Рассмотрим такую группу, ориентированную на события исключительно в Санкт-Петербурге. Ограничение зоны позволяет автоматически исправлять ошибки при определении нормальной формы адреса, упомянутого в тексте.

III. Заключение

При обработке данных были выявлены следующие проблемы: чаще всего ДТП происходят на пересечении улиц. При анализе такой записи будет выявлено две сущности, при этом, они описывают одно место. Необходимо разработать решение, позволяющее извлекать информацию о пересечениях дорог, чтобы точно размещать на карте место происшествия. Еще одна проблема – часто названия мест, упоминаемых в записях, используются в падежах, отличных от именительного. Это затрудняет процесс геокодирования, так как места на карте размечены именно в именительном падеже. Эта проблема может быть решена с помощью методов NLP или же с использованием словарей. Приведение географических названий к нормальной форме необходимо для точного позиционирования локаций на карте.

Таким образом, используя данные записей, опубликованных в социальной сети VK, можно использовать для нанесения происшествий на карту. Это может помочь, например, при использовании навигатора, полученная информация может позволить водителю заранее узнать о происшествии на дороге и помочь скорректировать маршрут, избежав проблемного места.

Список литературы

[1] Pestian J.P., Deleger L., Savova G.K., Dexheimer J.W., Solti I. Natural Language processing–the basics. Pediatric Biomedical Informatics: Computer Applications in Pediatric Research, 2012, pp. 149-172.

[2] Kuzmenko E. Morphological analysis for Russian: Integration and comparison of taggers. // Analysis of Images, Social Networks and Texts: 5th International Conference, AIST 2016, Yekaterinburg, Russia, April 7-9, 2016, Revised Selected Papers 5, Springer International Publishing, 2017, pp. 162-171.

[3] Araujo A.F., Golo M.P.S., Marcacini R.M. Opinion mining for app reviews: an analysis of textual representation and predictive models // Automated Software Engineering, 2022, vol. 29, pp. 1-30.

[4] Kadhim A.I. Term weighting for feature extraction on Twitter: A comparison between BM25 and TF-IDF. // 2019 international conference on advanced science and engineering (ICOASE), 2019, pp. 124-128.

[5] Gao X., Cao J., He Q., Li J. A novel method for geographical social event detection in social media // Proceedings of the fifth international conference on internet multimedia computing and service, 2013, pp. 305-308.

Возможности глубокого обучения применительно к задаче компьютерного моделирования тонкостенных оболочечных конструкций

Ю. Н. Згода
Санкт-Петербургский государственный архитектурно-строительный университет
yurii.zgoda@mail.ru

Аннотация. **В данной работе рассматриваются особенности применения методов глубокого обучения для расчета тонкостенных оболочек. Предложена процедура подготовки обучающего набора данных и архитектура нейронной сети. Проведена апробация нейросети на различных конфигурациях оболочек. Показано, что нейросетевое моделирование оболочек позволяет на несколько порядков сократить длительность моделирования без существенных потерь в точности вычислений.**

Ключевые слова: оболочки, компьютерное моделирование, глубокое обучение, нейронные сети, Julia, производительность, метод Ритца

I. Обзор литературы

Тонкостенные оболочечные конструкции или оболочки – это криволинейные конструкции, у которых один из размеров значительно меньше двух других [1]. Пример оболочки приведен на рис. 1.

Компьютерное моделирование оболочек представляет собой сложную вычислительную задачу. Различные свойства материалов конструкции и сложная геометрия приводят к высокой длительности вычислений. Это усложняет сравнительный анализ прочностных характеристик оболочек и влечет за собой существенные экономические затраты.

В области архитектуры и строительства все чаще применяют методы машинного обучения и, в частности, нейронные сети [2]. При моделировании строительных конструкций нейросети часто используются как альтернатива эмпирическим формулам [3] и позволяют с высокой точностью определять критическую нагрузку конструкции (под критической нагрузкой понимается такая прикладываемая к конструкции нагрузка, при которой даже незначительное ее увеличение приводит к существенной деформации). В тех случаях, когда отсутствует возможность провести необходимые для обучения сети физические эксперименты, возможно применение компьютерного моделирования для подготовки необходимых данных [4].

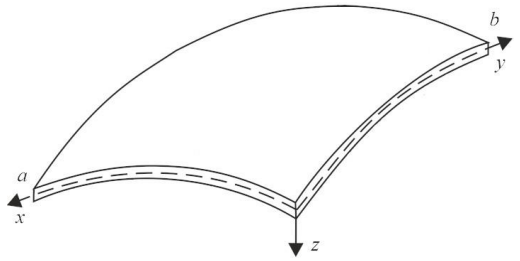

Рис. 1. Схематическое изображение оболочки

Оригинальный подход по использованию нейросетей при моделировании строительных конструкций был предложен в работе [5], посвященной моделированию плит (которые можно считать частным случаем оболочек без криволинейности). Авторами описывается нейросеть, принимающая на вход геометрические характеристики плиты и позволяющая определить прогиб и напряжение в произвольной ее точке. При этом вычисления с использованием нейросети производятся значительно быстрее в сравнении с компьютерным моделированием посредством ПО Ansys.

Из проведенного обзора можно сделать вывод, что компьютерное моделирование строительных конструкций как научное направление активно развивается, но количество работ по данной теме ограничено. В связи с этим не до конца очевидны свойства подобных нейросетей и их преимущества по сравнению с классическими методами компьютерного моделирования.

II. Методология

Целью данной работы является анализ особенностей применения методов глубокого обучения к компьютерному моделированию тонкостенных оболочечных конструкций. В рамках данной цели были решены следующие задачи:

- разработана архитектура нейронной сети моделирования цилиндрических оболочек и подход к ее обучению. Обученная нейросеть позволяет варьировать прикладываемую нагрузку, геометрические и физические характеристики моделируемой конструкции.
- Изучена точность моделирования оболочек с использованием разработанной нейросети.

- Исследована производительность моделирования с использованием нейронной сети в сравнении с классическим подходом к моделированию.

III. Результаты

В предыдущей работе [6] нами была предложена архитектура нейросети моделирования двояковыпуклых оболочек и процедура ее обучения. В связи с этим, в рамках данной работы вопрос обучения нейросети рассматривается поверхностно, основное внимание уделено архитектуре сети и ее свойствам.

Для формирования обучающего набора данных было использовано оригинальное высокопроизводительное ПО компьютерного моделирования оболочек OptiShellX [7]. ПО разработано на языке программирования Julia и позволяет выполнить моделирование оболочечных конструкций в безразмерных параметрах с учетом геометрической нелинейности путем аппроксимации функционала полной потенциальной энергии деформации по методу Ритца [8] и его минимизации с использованием метода продолжения решения по наилучшему параметру [9]. Для сокращения длительности вычислений был реализован ряд оригинальных оптимизаций [10]. Все приведенные далее результаты классического (без использования нейросетей) компьютерного моделирования были получены с использованием OptiShellX.

В рамках данной работы рассматриваются цилиндрические оболочки, определяемые следующими характеристиками: линейным размером a, углом разворота b, толщиной конструкции h и радиусом раскрытия R. Материал конструкции – изотропный, поэтому для его описания необходимы 3 параметра: E (модуль упругости), G (модуль сдвига) и μ (коэффициент Пуассона). Внешние силы приложены нормально к поверхности оболочки и являются равномерно-распределенными.

При расчете по методу Ритца для каждой из пяти двухмерных аппроксимируемых функции, описывающих напряженно-деформированное состояние (или НДС) конструкции, использовалось 16 аппроксимационных слагаемых. В соответствии с моделью Тимошенко-Рейснера [7], этими функциями являются поперечные перемещения U, продольные перемещения V, вертикальный прогиб W, углы поворота Ψ_x и Ψ_y вдоль плоскостей XOZ и YOZ соответственно.

Диапазон изменения параметров оболочки при формировании набора данных: $a \in [10\text{ м}, 40\text{ м}]$ с шагом 5 м (итого 7 значений); $b \in \left[\frac{\pi}{2}\text{ рад}, \pi\text{ рад}\right]$ с шагом $\frac{\pi}{12}$ рад или 15° (итого 7 значений); $h \in [0.01\text{ м}, 0.05\text{ м}]$ с шагом 0.01 м (итого 5 значений); $R \in [5\text{ м}, 25\text{ м}]$ с шагом 5 м (итого 6 значений).

В качестве возможных материалов были выбраны: сталь (E = 2.10e5 МПа, G = 8.07e4 МПа, μ = 0.30), титан (E = 1.16e5 МПа, G = 4.38e4 МПа, μ = 0.32) и алюминий (E = 0.71e5 МПа, G = 2.62e4 МПа, μ = 0.35). Отметим, что ввиду изотропности материала параметр G может быть опущен, он выводится из двух других. Итого для описания конфигурации оболочки нужно 6 параметров.

Был выполнен расчет 4 410 цилиндрических оболочечных конструкций. Полученные результаты расчета были случайным образом разделены на 80 % обучающих данных, 10 % валидационных данных и 10 % тестовых данных. Дополнительно, перед обучением нейросети все конфигурации были преобразованы в безразмерную форму [11]. Это позволяет значительно расширить диапазон допустимых конструкций на все те конструкции, которые подобны по геометрии используемым в процессе обучения. Количество геометрических и физических параметров в безразмерной постановке также равно шести. Также входными параметрами нейросети являются параметры q (прикладываемая нагрузка, МПа), x и y (локальные безразмерные координаты, диапазон изменения от 0.0 до 1.0). Итого нейросеть принимает на вход 9 параметров.

Выходными данными сети являются значения пяти функций U, V, W, Ψ_x, Ψ_y в точке (x, y).

Архитектура нейросети имеет следующий вид:

- Входной слой состоит из 9 параметров.
- За ним следует слой Batch Normalization (BN).
- За ним следуют 5 полносвязных слоев по 162 каждый, активационная функция – ReLU.
- Выходные данные последнего слоя, а также входные данные нейросети (путем проброски) передаются в 5 независимых подсетей:
    - Входной слой – 171 нейрон.
    - За ним следует слой BN.
    - Далее 4 полносвязных слоя по 171 нейрон каждый, активация – ReLU.
    - Каждая из подсетей завершается одним нейроном с единичной активацией.
- Выходные нейроны 5 подсетей образуют выходной вектор сети.

Для реализации нейросети использовался язык программирования Julia и библиотека Flux.jl. При обучении использовалась функция потерь Mean Absolute Error (MAE) и алгоритм ADAM.

Для наглядной демонстрации возможностей моделирования с использованием указанной нейросети рассмотрим оболочечную конструкцию со следующими параметрами: a = 25 м, b = 2.88 рад, R = 13 м, h = 0.05 м, материал – алюминий. На рис. 2 приведены диаграммы «нагрузка-компонента НДС» для каждой из 5 компонент в центре (координаты $x = y = 0.5$) и четверти ($x = y = 0.25$) срединной поверхности оболочки. Изменяемая переменная (прикладываемая нагрузка) на диаграммах отложена по вертикали, а моделируемая величина – по горизонтали.

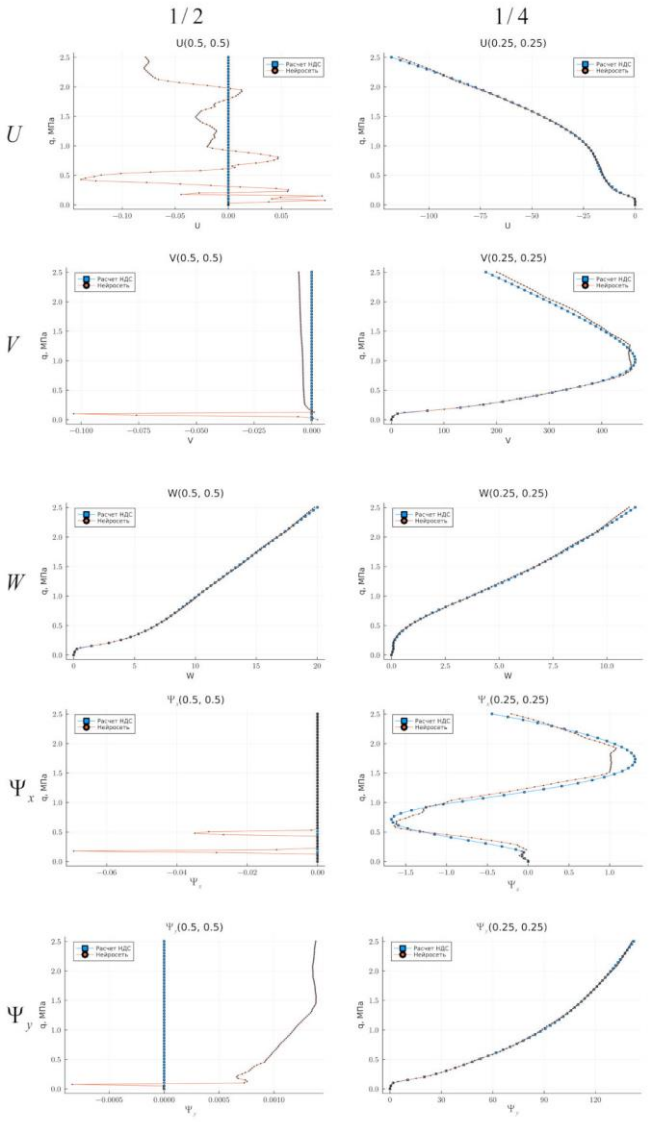

Рис. 2. Расчет цилиндрической оболочки с использованием нейросетевого и классического компьютерного моделирования (синий цвет – результаты классического расчета, красный – результаты нейросетевого расчета)

Как можно видеть, практически во всех случаях результаты моделирования с использованием нейросети совпадают с результатами классического компьютерного моделирования. Исключение составляют диаграммы с около-нулевыми значениями, где нейросетевой расчет колеблется около нуля с незначительной погрешностью.

Приведенные выше диаграммы показывает высокую точность моделирования на конкретной конструкции, но не позволяют сделать вывод о возможностях обобщения нейросети. В связи с этим был проведен вычислительный эксперимент на 48 оболочечных конструкциях с непересекающимися геометрическими характеристиками: $a \in$ (17.5 м, 22.5 м, 27.5 м), $b \in$ (112°, 127.5°, 142.5°), $h \in$ (0.025 м, 0.035 м, 0.045 м), R $\in$ (12.5 м, 17.5 м, 22.5 м), материал: сталь, титан, алюминий. Этот набор не пересекается с обучающим набором данных. Значение функции потерь на нем несущественно больше аналогичного значения на тестовом наборе данных, т. е. обучение сети прошло успешно.

Разработанное решение позволяет в определенной степени выйти за пределы обучающей выборки как по геометрическим, так и по физическим характеристикам. В качестве примера рассмотрим диаграммы «нагрузка-прогиб» для модификаций ранее описанной оболочки с линейным размером a = 10 м и углами раскрытия 180°, 210°, 240°, 270°. В обучающем наборе максимальный угол раскрытия равен 180°, поэтому остальные 3 варианта являются для сети «незнакомыми». Результаты моделирования приведены на рис. 3. Видно, что при малом увеличении угла раскрытия b нейросеть выдает достаточно точные результаты. Лишь при b = 270° наблюдается существенное отклонение от результатов классического расчета.

Для апробации возможностей нейросети по моделированию произвольных материалов рассмотрим гипотетический материал, описываемый параметрами E = 1.63e5, G = 6.23e4, μ = 0.31, а также медь (E = 1.00e5, G = 3.70e4, μ = 0.35). На рис. 4 приведены диаграмма «нагрузка-прогиб» для первой рассмотренной конфигурации (сверху), для ее модификации с использованием абстрактного материала (по центру) и меди (снизу). Видно, что отклонение от результатов аналитического расчета при использовании абстрактного материала увеличилось, но не настолько, чтобы результаты нельзя было использовать для предварительной оценки НДС конструкции. Для меди наблюдается более значимая ошибка моделирования, однако линейный участок диаграммы и локальная потеря устойчивости были определены корректно.

Моделирование оболочек классическим методом требует активного использования многоядерного процессора и графического ускорителя, а также предполагает множество этапов вычислений [9], поэтому очевидным свойством предлагаемой нейросети является высокая скорость моделирования.

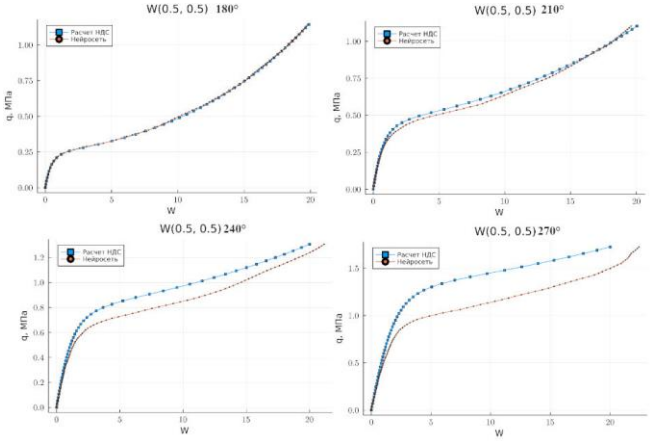

Рис. 3. Расчет оболочек при использовании углов раскрытия, отсутствующих в обучающей выборке. Углы раскрытия: 180° (слева сверху), 210 ° (справа сверху), 240° (снизу слева), 270°(снизу справа)

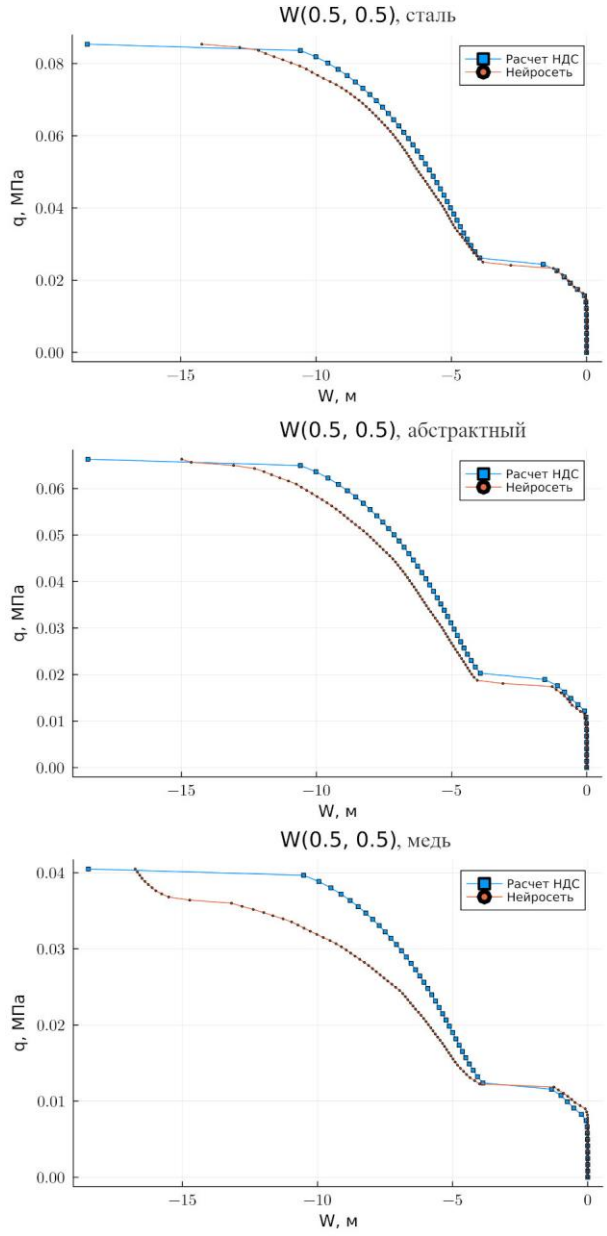

Рис. 4. Моделирование оболочек с материалами, не использованными в процессе обучения

Среднее время моделирования одной оболочки классическим методом – примерно 9.72 секунды, в то время как для выполнения аналогичного нейросетевого расчета достаточно 0.01 с, что в 972 раза быстрее.

Классический подход к компьютерному моделированию не позволяет рассчитать конструкцию лишь в одной ее точке, конструкция должна быть смоделирована целиком. Кроме того, в большинстве случаев невозможно выполнить расчет для какого-то конкретного значения прикладываемой нагрузки. Классическое моделирование требует постепенного увеличения прикладываемой нагрузки. Предложенная нейросеть лишена всех этих недостатков и позволяет определить НДС в произвольной точке конструкции при произвольном нагружении без необходимости в расчете предыдущих значений нагрузки. Этот факт дополнительно способствует сокращению длительности вычислений.

IV. Заключение

Все поставленные в рамках данной работы цели выполнены. Обучена нейросеть моделирования цилиндрических оболочек, способная с высокой точностью моделировать этот тип конструкций. Она показала низкую погрешность на тестовом наборе, позволяет с достаточной точностью экстраполировать результаты обучения на неизвестные ей геометрические и физические конфигурации оболочек, а также обеспечивает сокращение длительности вычислений примерно в 970 раз, что позволяет значительно ускорить сравнительный анализ конструкций.

Список литературы

[1] Карпов В. В. Прочность и устойчивость подкрепленных оболочек вращения. В 2 ч. Ч.1. Модели и алгоритмы исследования прочности и устойчивости подкрепленных оболочек вращения. М.: ФИЗМАТЛИТ, 2010. 288 с.

[2] Xu Y., Zhou Y., Sekula P., Ding L. Machine learning in construction: From shallow to deep learning // Developments in the Built Environment. 2021. Vol. 6. P. 100045.

[3] Hosseinpour M., Sharifi Y., Sharifi H. Neural network application for distortional buckling capacity assessment of castellated steel beams // Structures. 2020. Vol. 27. P. 1174–1183.

[4] Sun Z. Lei Z., Bai R., Jiang H., Zou J., Ma Y., Yan C.. Prediction of compression buckling load and buckling mode of hat-stiffened panels using artificial neural network // Engineering Structures. 2021. Vol. 242. P. 112275.

[5] Ribeiro J., Tavares S., Parente M. Stress-strain evaluation of structural parts using artificial neural networks // Proceedings of the Institution of Mechanical Engineers Part L Journal of Materials Design and Applications. 2021. P. 1271–1286.

[6] Zgoda Iu.N. High performance modeling of the stress-strain state of thin-walled shell structures with the use of deep learning // Scientific and Technical Journal of Information Technologies, Mechanics and Optics, 2023, vol. 23, no. 2 (в печати)

[7] Свидетельство 2023612571. OptiShellX – программа для высокопроизводительного расчета тонкостенных оболочечных конструкций : программа для ЭВМ / Згода Ю. Н (RU); правообладатель ФГБОУ ВО «Санкт-Петербургский государственный архитектурно-строительный университет». № 2023611473; заявл. 27.01.2023, опубл. 06.02.2023.

[8] Karpov V.V. Models of the shells having ribs, reinforcement plates and cutouts // International Journal of Solids and Structures. 2018. Vol. 146. P. 117–135.

[9] Семенов А.А., Леонов С.С. Метод непрерывного продолжения решения по наилучшему параметру при расчете оболочечных конструкций // Ученые записки Казанского университета. Серия: физико-математические науки. 2019. Т. 161, № 2. С. 230–249.

[10] Згода Ю.Н., Семенов А.А. Высокопроизводительный расчет тонкостенных оболочечных конструкций с использованием параллельных вычислений и графических ускорителей // Вычислительные Технологии. 2022. Т. 27, № 6. С. 45–57.

[11] Карпов В.В., Семенов А.А. Безразмерные параметры в теории подкрепленных оболочек // Вестник ПНИПУ. Механика. 2015. № 3. С. 74–94.

Применение нейронной сети для оценки пользовательского опыта работы с приложением

В. А. Юркин, С. Э. Сараджишвили, Н. В. Воинов, С. А. Молодяков
Санкт-Петербургский политехнический университет Петра Великого
voinov@ics2.ecd.spbstu.ru

Аннотация. **Предложен подход к оценке пользовательского опыта работы с приложением на основе применения свёрточной нейронной сети для распознавания эмоций пользователя. Оценка формируется через привязку эмоционального отклика и внимания к конкретным моментам работы с приложением и графическим элементам интерфейса в режиме реального времени.**

Ключевые слова: оценка пользовательского опыта; свёрточная нейронная сеть; графический интерфейс; обучение модели

I. Введение

Инструментом взаимодействия пользователя с программным приложением является интерфейс приложения. Комфорт и эффективность работы с приложением напрямую зависят от правильной компоновки графических элементов интерфейса на экране, а также возможности их реорганизации на рабочем пространстве в зависимости от нужд различных категорий пользователей. Проектирование интерфейса и создание шаблонных схем компоновки базируется на различных методиках оценки, таких как: анкетирование, бенчмарки, различного рода тесты и отзывы. В настоящее время активно развиваются системы, базирующиеся на автоматизированном получении оценки напрямую от пользователя через его эмоциональный отклик, т. к. часто оценки, предоставленные специальными программами, основанными на формальных методах, расходятся с конечным мнением пользователей.

Преимуществами получения оценки непосредственно от пользователя без непосредственного участия являются значительный рост информации доступной для анализа, исключение необходимости периодического опроса, возможность оценки отдельных изменений в процессе разработки, отслеживание динамики корреляции эффективности работы с приложением от вносимых изменений.

Формирование оценки интерфейса и его элементов, основываясь на анализе эмоций человека, является сложно реализуемой задачей в реальных условиях. Существующие методы предполагают использование узконаправленных подходов, таких как отслеживание взгляда, распознавание эмоций для видеоряда или оценка внимания в группах, что не позволяет получить достаточные данные для анализа сопоставимые с традиционными методами оценки. Также существуют методы, основанные на использовании электроэнцефалограммы, позволяющие проводить качественный анализ с привязкой ко времени и координатам, но требующие непосредственного участия испытуемых для работы, что исключает возможность их повсеместного применения. Таким образом, существует задача динамической оценки графического интерфейса программного продукта, основываясь на пользовательских опыте и эмоциях в режиме реального времени.

В последнее время стали применятся методы, основанные на применении нейронных сетей, которые позволяют извлекать необходимую информацию без прямого обращения к пользователю. Наиболее распространён подход с использованием распознавания эмоций для видео контента [1, 2]. В этой работе предлагается использовать распознавание эмоций и концентрации внимания для оценки приложения целиком.

II. Обзор существующих работ

Работы, связанные с данной темой, можно разделить на две группы: работы по построению нейронных сетей для распознавания эмоций и работы по получению эмоционального отклика пользователя на потребляемый цифровой контент. К первой группе относятся многочисленные работы с использованием различных архитектур нейронных сетей, достигающих точности распознавания базовых типов эмоций в 99 % в лабораторных условиях и комбинировании нейронных сетей (5–7 вариаций плюс нейтральное выражение лица) и 70–90 % при нормальных условиях и одной нейросети. Вторая группа ориентирована на привязку эмоций пользователя к какому-либо цифровому контенту [3–8]. Исследования компании RealEyes [9] и группа под руководством М. Сулеймани показали, что пользователь проявляет эмоции в среднем 13 % времени от просмотра видеоконтента и корреляция между распознаваемыми эмоциями и показаниями энцефалограммы 74 % [10].

Большинство рассмотренных методов используют лишь часть информации, получаемой из видеопотока, и часто являются узконаправленными решениями с упором на максимальную точность результатов. Таким образом, были сделаны следующие выводы о текущем положении в исследуемой области:

- Большинство предлагаемых решений включает подходы, заточенные на максимальную точность результата, что не имеет первостепенного значения для решения задачи на больших объёмах данных от множества пользователей, предоставляемых в реальном времени.
- Используется лишь часть полезной и доступной для анализа информации, извлекаемой из видеопотока.
- Использование электроэнцефалограммы даёт максимально точные результаты с наивысших

объёмов фиксируемых откликов, но не может быть использовано для решения задачи ввиду недопустимости использования на постоянной основе для большого количества лиц во время повседневной работы с продуктом.

- Многие исследования ставят своей целью достижения определённых результатов в соревновательном ключе задачи распознавания, не учитывая необходимость дальнейшего дообучения и использования наборов данных, которые должны быть получены в рабочем режиме без специальной подготовки.

Изложенные результаты позволяют заключить, что в настоящее время нет открытых технологий, которые бы позволяли проводить автоматизированную качественную оценку цифрового программного продукта в режиме реального времени, основываясь на анализе нейронными сетями комбинации определения внимания, эмоций и утомляемости пользователя, получаемых с видеопотока с привязкой к конкретным элементам.

III. Предлагаемый подход

Внимание пользователя фиксируется как во время активного взаимодействия с элементами интерфейса через привязку к используемым функциям и элементам, так и во время простоя, т. е. отсутствия какой-либо активности в программе, но в присутствии пользователя. Степень утомляемости определяется как соотношение времени потери внимания и количества таких случаев к общему времени использования программы, как активного, так и пассивного в привязке к изменению в интерфейсе.

Метод комплексной оценки заключается в формировании для каждого элемента интерфейса и продукта целиком набора оценочных характеристик, формируемых из получаемых данных на этапе распознавания эмоций, внимания и утомляемости на основании статистики. В зависимости от реакции пользователя на какие-либо функции и элементы интерфейса накапливаются статистические данные для формирования различных профилей. На первоначальном этапе предполагается использование базового профиля для всех категорий пользователей до накопления необходимой информации. Для оценки работы пользователя с приложением предлагаются следующие критерии:

- Эффективность – точность и полнота, с которой пользователи достигают поставленных целей. Определяется как соотношение минимально необходимого количества действий для выполнения задачи к затраченному количеству действий.
- Продуктивность – отношение функциональной ценности к затрачиваемому времени. Определяется как минимальное количество необходимых для выполнения задачи действий к затраченному времени.
- Производительность – ресурсы, затраченные на выполнение действия относительно полноты и точности для достижения цели. Определяется как соотношение эффективности к затрачиваемому времени.
- Ошибочность – степень корректности применяемых действий для достижения цели. Определяется как соотношение некорректных действий ко всем действиям, выполняемым для решения данной задачи.

Для определения рекомендаций по построению интерфейса предполагается использование как комплексной оценки на основании вышеперечисленных критериев и эмоционального отклика на событие, так и отдельных показателей. Оценка формируется на протяжении всего использования программного продукта и сравнивается с аналогичной для различных версий и схем компоновки в зависимости от сформированных профилей. Для элементов интерфейса на основании комплексной оценки формируются веса, определяющие их параметры: общую эффективность, количество использований, время на поиск, эмоциональный отклик, динамику по времени.

IV. Реализация

Основная идея заключается в построении свёрточной нейронной сети для распознавания эмоций и ее обучении на наборе данных FER+ с достижением точности в 80–85 %. Планируется осуществить формирование оценки приложения через привязку эмоционального отклика и внимания к конкретным моментам работы с приложением и графическим элементам интерфейса в режиме реального времени. Эмоции пользователя фиксируются с помощью камеры во время работы с приложением.

Для обучения модели использовались 5 слоев с функцией активации Rectified Linear Unit (ReLU) для отсечки лишних участков в канале с отрицательным выходом и выходной слой с функцией активации SoftMax для получения суммы выходных значений, где вся группа равна 1. На рис. 1 представлена архитектура нейронной сети.

Слой
Conv2D
ReLU
Conv2D
Max Pool
DropOut
Conv2D
ReLU
Conv2D
Max Pool
DropOut
Conv2D
ReLU
Conv2D
Max Pool
Flatten
Dense
DropOut
Dense
SoftMax

Рис. 1. Архитектура нейронной сети

Использовался вероятностный подход к рисованию меток. Такой подход хорошо показал себя для набора FER+ в аналогичных исследованиях. После нескольких этапов обучения удалось приблизиться к истинному значению метки эмоции в среднем. Входное изображение имеет размер 48*48 пикселей. Три максимальных пула с использованием областей 2x2 с шагом 2. Всего параметров – 1921377, обучаемых параметров – 1921377, необучаемых параметров – 0.

Итоговая точность распознавания для 7 базовых эмоций и нейтрального состояния составила 84.1 %, также нейросеть была обучена отслеживать внимание и утомляемость [11].

Для проведения исследования использовалась тестовая программа по моделированию автомобильного трафика в городе. Для видеопотока была выбрана частота кадров 30. Семь базовых эмоций были разбиты на подгруппы, которые условно определяют негативную или позитивную реакцию пользователя. Для всех функций в программе реализовано полное логирование. Каждый пользователь характеризуется собственной историей реакции, благодаря чему вносятся корректирующие коэффициенты от 0 до 1 для определения оценки. Статистически определяется, является ли угол отклонения и время соответствующими отвлечению для конкретного пользователя. Для утомляемости определяется степень от 0 до 1, а также скорость её набора со временем. Введён понижающий коэффициент для повторных событий, снижения реакции со временем. Пользователи разделены на условные группы по типичному поведению в программе (администратор, разработчик, пользователь), которые определены изначально и в дальнейшем изменяются с набором статистических данных. Оценка для одиночного события рассчитывается по формуле (1), где S_i – оценка одиночного события, E_i – эмоциональная оценка, U_j – пользовательский коэффициент для эмоции, T_i – коэффициент временного затухания:

$$S_i = E_i * U_j * T_i \quad (1)$$

ТАБЛИЦА I. РЕЗУЛЬТАТЫ ТЕСТИРОВАНИЯ

Соответствие распознаваемых эмоций согласно анкете	82,5 %
Соответствие распознаваемых эмоций согласно энцефалограмме	79,7 %
Соответствие оценки пользователя на событие из анкеты и полученному программно	78,1 %
Соответствие оценки пользователя на программу в целом из анкеты и полученному программно	94,1%
Соответствие оценки утомляемости	74,5 %

Общая оценка на одинаковые события рассчитывается как сумма одиночных, где значимость каждой последующей во времени снижается по экспоненте, т. к. опытным путём установлено значительное падение реакции на идентичное событие. Отдельно рассчитываются интегральные эмоциональные оценки для всей программы в целом и изменениям с версиями программы. Дополнительно рассчитывается коэффициент утомляемости как медианный для группы пользователей.

V. РЕЗУЛЬТАТЫ

Тестирование проводилось на протяжении 3 месяцев группой испытуемых из 20 человек, работавших с приложением в среднем 4 часа в день на добровольной основе. Для тестирования программы было выбрано 20 пользователей, обученных обращению с программой, каждый из которых прошёл анкетирование на соответствие его эмоций распознаваемым и на корреляцию его оценки к программной. Усреднённые результаты представлены в табл. 1. Проведено исследование с помощью энцефалограммы для одного пользователя на соответствие эмоций.

Количество не нейтральных реакций на событие – 12,7 %, отвлечения – 3,6 % от общего времени против – 13 % и 8 % соответственно представленных в исследовании RealEyes для видеоконтента, но необходимо отметить, что сравнивать результаты напрямую нельзя из-за различия видео контента и программ, а также физической невозможности проведения испытания на одной и той же большой группе лиц.

VI. ЗАКЛЮЧЕНИЕ

Обучение для текущей архитектуры нейросети выполняется за приемлемое время с высокой точностью, сопоставимой с аналогичными работами в данном направлении. Для теста на FER+ результат 84,1 %, что соответствует первой десятке в рейтинге алгоритмов. Результаты тестирования системы оценивания на уровне или превосходят конкурентов, насколько это возможно сравнить, т. к. большинство из них не раскрывают свои алгоритмы и показатели. Предлагаемый подход может использоваться для мобильных и настольных систем. Требуемая точность достигнута с предлагаемой архитектурой. Результаты, полученные в ходе анкетирования и работы программы, имеют высокую степень корреляции. В рамках тестирования получено более 12000 оценок. Степень соответствия оценки для программы в целом достаточно высока для возможности массового использования данного метода для замены анкетирования, опросов и системы ручного оценивания там, где это возможно. Для значительного повышения точности требуется усложнение алгоритма, что приведёт к потере скорости работы программы в целом из-за повышения вычислительной сложности. В данной работе соотношение скорость/точность определяется исходя из необходимости обработки большого количества оценок, поэтому высокая точность не требуется. Важным препятствием остаётся несбалансированность наборов для обучения. В дальнейшем возможно улучшение алгоритма за счёт расширения наборов для обучения и улучшения алгоритмов для определения степени утомляемости и отвлечения.

СПИСОК ЛИТЕРАТУРЫ

[1] Cooper A., Reiman R., Cronin D., Noessel C. About Face: The Essentials of Interaction Design. Wiley; 4th edition, 2014. 720 p.

[2] Garrett J.J. The Elements of User Experience: User-Centered Design for the Web and Beyond. Peachpit Pr, 2002. 240 p.

[3] Poria S., Cambria E., Bajpai R., Hussain A. A review of affective computing: From unimodal analysis to multimodal fusion. Information Fusion. 2017, vol. 37, pp. 98-125. DOI: https://doi.org/10.1016/j.inffus.2017.02.003

[4] Barsoum E., Zhang C., Ferrer C.C., Zhang Z. Training Deep Networks for Facial Expression Recognition with Crowd-Sourced Label Distribution. 2016.

[5] Goodfellow I.J., Erhan D., Carrier P.L., Courville A., Mirza M., Hamner B., Cukierski W., Tang Y., Thaler D., Lee D.-H., Zhou Y., Ramaiah C., Feng F., Li R., Wang X., Athanasakis D., Shawe-Taylor J., Milakov M., Park J., Ionescu R., Popescu M., Grozea C., Bergstra J., Xie J., Romaszko L., Xu B., Chuang Z., Bengio Y. Challenges in Representation Learning: A report on three machine learning contests. 2013.

[6] Siqueira H., Magg S., Wermter S. Efficient facial feature learning with wide ensemble-based convolutional neural networks. Proceedings of the AAAI Conference on Artificial Intelligence. 2020,

vol. 34(04), pp. 5800-5809. DOI: https://doi.org/10.1609/aaai.v34i04.6037

[7] Mollahosseini A., Chan D., Mahoor M.H. Going deeper in facial expression recognition using Deep Neural Networks. 2015. DOI: https://doi.org/10.1109/WACV.2016.7477450

[8] Li Y., Zeng J., Shan S., Chen X. Occlusion aware facial expression recognition using CNN with attention mechanism. IEEE Transactions on Image Processing. 2019, vol. 28, pp. 2439-2450. DOI: https://doi.org/10.1109/TIP.2018.2886767

[9] Soleymani M., Pantic M., Pun T. Multimodal emotion recognition in response to videos. IEEE Transactions on Affective Computing. 2012, vol. 3, pp. 211-223. DOI: https://doi.org/10.1109/T-AFFC.2011.37

[10] Real Eyes: White Paper. Emotion Recognition. Режим доступа: https://docs.realeyesit.com/Realeyes_Whitepaper.pdf?utm_campaign=White%20Paper&utm_medium=email&_hsenc=p2ANqtz-_mRisDPDpE5Vtv6fVPTCd8IF-hzHOFCXJIjf7dawcPykr1KhtdGjwBNxvo-BZtC2vlrwEffpAJnPgwWSi65z5CM3AQBw&_hsmi=81880641&utm_content=81880641&utm_source=hs_automation&hsCtaTracking=29b79d0b-6267-4666-ad0c-d608a1e93ca7%7C78a2377c-8116-4650-8706-abd1e90acf51 (доступ 24 марта 2023).

[11] Sagonas C., Tzimiropoulos G., Zafeiriou S., Pantic M. A semi-automatic methodology for facial landmark annotation. IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops. 2013, pp. 896-903. DOI: https://doi.org/10.1109/CVPRW.2013.132.

Модель иерархической кластеризации субъектов Федерации по уровню их импортозависимости

Е. С. Митяков[1], А. И. Ладынин[2], А. Г. Шмелева[3]
МИРЭА – Российский технологический университет
[1]iyao@mail.ru, [2]andrey.ladynin@hotmail.com,
[3]ann_shmeleva@mail.ru,

Н. А. Мурашова[1], С. Н. Митяков[2]
Нижегородский государственный технический университет им. Р.Е. Алексеева
[1]murashova_nat@mail.ru, [2]snmit@mail.ru

***Аннотация*. В работе предложена одна из возможных моделей кластеризации регионов России по уровню их импортозависимости. Решение сложно формализуемой задачи кластеризации регионов по уровню импортозависимости, выполнено с использованием математического аппарата иерархической кластеризации на базе данных Федеральной службы государственной статистики РФ. Для формирования системы критериев кластеризации были отобраны официальные статистические данные товарной структуры внешнеэкономической деятельности Российской Федерации по 6 группам: продовольственные товары и сельскохозяйственное сырье; продукция топливно-энергетического комплекса; продукция химической промышленности, каучук; древесина и целлюлозно-бумажные изделия; металлы и изделия из них; машины, оборудование и транспортные средства. В работе осуществлен выбор алгоритма кластеризации. Вычислительный эксперимент, проведенный для регионов Приволжского и Центрального федерального округов, наглядно продемонстрировал уровень импортозамещения в субъектах Федерации.**

Ключевые слова: машинное обучение, кластерный анализ, иерархическая кластеризация, импортозамещение, импортозависимость, регионы Российской Федерации, дендрограмма

I. Введение

Турбулентная мировая геополитическая ситуация диктует целесообразность развития политики импортозамещения для многих государств мирового сообщества [1]. Современные экономические и геополитические реалии диктуют целесообразность развития региональной политики РФ, а также формирования новой парадигмы и обоснования императивов ее развития. В условиях новой геополитической обстановки в 2022–2023 гг., беспрецедентных санкций со стороны некоторых стран против России, нарушения цепочек поставок и международной кооперации требуется принятие экстренных мер, связанных с кардинальной трансформацией экономики страны в целом, и ее промышленного комплекса в частности. Вместе с тем, на сегодняшний день можно констатировать инерционность регионального развития, значительную пространственную дифференциацию территорий, а также существенную импортозависимость региональных экономических систем.

Сегодня требуется поиск новых действенных механизмов реиндустриализации и импортоопережения в отечественной экономике. Все большую актуальность в сложившейся ситуации приобретает национализация экономики России и ее регионов [2, 3]. Характер данной тенденции проявлялся и ранее, однако на сегодняшний момент остро стоит вопрос о полном импортозамещении, импортоопережении и реиндустриализации во всех секторах экономики с целью сохранения достойного качества жизни народонаселения. Именно поэтому в Российской Федерации на данный момент активно дорабатываются и развиваются разнообразные программы по импортозамещению.

Развитие новых методологических подходов к обеспечению импортозамещения, реиндустриализации и импортоопережения в региональных экосистемах обусловлено необходимостью формирования новых действенных механизмов управления процессами развития в субъектах Федерации, осуществляемого за счет появления достаточного количества мобилизационных ресурсов, отвечающих современным требованиям на основе вертикальной интеграции.

Важно отметить, что для адекватного проведения политики активного импортозамещения в России необходимо учитывать специфику и особенности российской промышленности: существующий уровень технологий, доступный объем инвестиций в новые проекты, отраслевую специализацию страны в рамках мирового хозяйства. Кроме этого, необходимо проанализировать возможности импортозамещения на региональном уровне.

Учитывая тот факт, что субъекты Федерации имеют различную инфраструктуру, а также серьезно разнятся по уровню развития отраслей экономики, представляется актуальным провести информационно-статистический анализ процессов импортозамещения в промышленности в регионах РФ.

Методологические основы обеспечения импортозамещения региональных экосистем должны быть сформированы на базе междисциплинарого подхода с использованием современных технологий управления, информационных технологий и элементов экономико-математического моделирования.

В информационной поддержке принимаемых решений успешно используется технология кластерного анализа [4]. Она нашла свое применение в областях с высокой степенью ответственности: стратегическом планировании [5], региональной политике [6] и др.

Целью данной работы является проведение экономико-математического анализа импортозависимости в регионах РФ с использованием

математического инструментария иерархической кластеризации.

II. Постановка задачи

В настоящее время доступность значительного Приведем формализованную постановку задачи кластеризации. В контексте решаемой задачи итогом проведения кластерного анализа станут кластеры субъектов Федерации, схожих по уровню импортозависимости. При этом каждый кластер должен получить экономическую интерпретацию с точки зрения импортозависимости экономики региона.

Приведем постановку задачи кластеризации в математической постановке. Допустим X − совокупность объектов кластеризации (субъектов Федерации), а Y − множество меток кластеров. Каждый объект анализа обладает множеством показателей C, характеризующих его импортозависимость субъекта.

Пусть обучающая выборка из n регионов: $X_n = (x_1, \ldots, x_n) \in X$. При этом каждому субъекту Федерации целесообразно поставить в соответствие ставится в соответствие набор значений m индикаторов импортозависимости показателей $C_n = (c_{n1}, \ldots, c_{nm}) \in C$.

При решении задачи кластеризации необходимо задать метрику расстояний между объектами анализа: $\rho(X_n; C_n)$. Задача состоит в разбиении исходной выборки регионов Y на k непересекающихся кластеров $Y = (y_1, ..., y_k)$. Каждый кластер должен состоять из субъектов Федерации максимально близких по метрике ρ, при этом регионы их разных кластеров должны существенно разнится. Каждому объекту анализа x_n ставится соответствует единственная метка кластера y_k. Кластеризация объектов осуществляется согласно некоторому алгоритму кластеризации

$$F : X \to Y$$

Таким образом кластерный анализ предназначен для разбиения данных об объектах исследования на интерпретируемые группы так, чтобы элементы, входящие в одну группу, были максимально «схожи», а элементы из разных групп были максимально «отличными» друг от друга [7].

Кластерный анализ позволяет рассматривать достаточно большой объем информации и сжимать его, что помогает делать последующий анализ более компактными и наглядными. Наиболее значимое достоинство кластерного анализа заключается в том, что он позволяет кластеризировать объекты исследования сразу по целому ансамблю параметров.

Применение методов кластеризации не накладывает значительных ограничений на вид анализируемых объектов, и позволяет рассматривать совокупность исходной информации практически произвольной природы. Данный факт выступает весьма существенным, когда показатели имеют разнообразный вид и размерность.

Для решения задачи кластеризации регионов по уровню импортозависимости необходимо придерживаться следующего укрупненного алгоритма:

1. формирование множества объектов, подлежащих кластерному анализу;
2. разработка системы показателей импортозависимости регионов
3. выбор и обоснование алгоритма кластеризации;
4. проведение численного эксперимента;
5. интерпретация результатов.

Множеством объектов исследования в статье выступает множество субъектов Федерации. Далее рассмотрим пункты 2–5 алгоритма, представленного выше.

III. Система показателей для кластеризации регионов по уровню импортозависимости

Показатели импортозамещения, реализуемого в РФ в последнее время, отражены в инфокоммуникационных ресурсах государственных статистических ведомств. Для формирования системы показателей для кластеризации субъектов Федерации по уровню импортозависимости на официальном сайте Федеральной службы государственной статистики [8] были отобраны статистические данные товарной структуры внешнеэкономической деятельности Российской Федерации, в которую входят 6 групп:

1. продовольственные товары и сельскохозяйственное сырье;
2. продукция топливно-энергетического комплекса;
3. продукция химической промышленности, каучук;
4. древесина и целлюлозно-бумажные изделия;
5. металлы и изделия из них;
6. машины, оборудование и транспортные средства.

Чтобы отобразить импортозависимость между регионами, был рассчитан процент импортозамещения в каждом регионе в отдельности. Для расчета данного процента необходимо найти данные товарной структуры ВЭД за каждый год по всем областям Российской Федерации, а также потребление товарной продукции в РФ. Найдя данные товарной структуры и потребления продукции страны, необходимо рассчитать процент импортозамещения по формуле:

$$\text{Коэф. импортозам.} = \left(\frac{\text{Импорт}}{\text{Потребление}}\right) \cdot 100\%.$$

В профильных научных изданиях можно найти значительное многообразие кластеризирующих алгоритмов. Как правило, их можно разделить на плоские и иерархические. С помощью первых можно получить одно разбиение исходного множества объектов на кластеры, а с помощью вторых – систему вложенных разбиений [9]. Следует отметить, что на сегодняшний день не существует однозначно наилучшего критерия качества кластеризации. При использовании разнообразных алгоритмов кластерного анализа для одного множества объектов исследования как правило могут получиться разные результаты, порой принципиально отличающиеся друг от друга.

В нашей задаче изначально определить количество кластеров довольно сложно. В таких случаях обычно задействуют иерархические кластерные процедуры, среди которых выделяют два ключевых типа:

нисходящие и восходящие. Первые основаны на принципе «сверху вниз»: сначала все объекты располагаются в одном кластере, который впоследствии декомпозируется на более мелкие группы. Вторые базируются на принципе «снизу вверх»: изначально каждый анализируемых объект помещается в отдельный кластер, который впоследствии объединяется в более крупные группы объектов. Таким образом, в обоих случаях строится система разбиений, вложенных друг в друга.

Результаты иерархических кластерных процедур удобно представлять в виде дендрограмм, которые показывают этапность разбиения (объединения) объектов на (в) кластеры, а также их метрику близости [10].

Для построения дендрограммы целесообразно найти матрицу сходства (или различия) между парами кластеров. Для ее поиска требуется определиться с критерием кластерной связи. Данный критерий идентифицирует способ расчета расстояния между кластерами, которое задействуется при объединении двух кластеров в рамках построения их иерархии. В научной литературе и в практической деятельности наиболее часто используются следующие методы определения критерия связи: метод одиночной связи (ближайшего соседа), метод полной связи (дальнего соседа), метод средней связи, метод Варда [11]. Таким образом в качестве алгоритма кластерного анализа в работе выбран иерархический алгоритм.

IV. Вычислительный эксперимент

В рамках проведения вычислительного эксперимента для расчетов импортозависимости субъектов Федерации было взято для рассмотрения и сравнения три временных промежутка: 2010 год, 2015 год и 2020 год, а также все восемь округов России со входящими в них регионами. Пример исходных данных для анализа представлен в табл. 1.

ТАБЛИЦА I. Показатели импортозамещения регионов ЦФО в 2019 г.

Регион	**1**	**2**	**3**	**4**	**5**	**6**
ЦФО	**25,40**	**1,27**	**54,61**	**17,02**	**15,69**	**59,51**
Белгородская область	2,22	2,07	28,31	13,28	7,24	65,18
Брянская область	12,17	0,17	21,61	13,43	14,90	23,64
Владимирская область	16,26	3,35	20,32	1,91	8,96	19,26
Воронежская область	4,90	4,78	7,31	7,56	19,14	16,90
Ивановская область	9,73	0,28	25,17	5,64	6,44	24,19
Калужская область	6,83	1,31	33,56	11,61	27,03	39,12
Костромская область	2,72	0,10	16,63	2,68	1,81	11,02
Курская область	3,05	0,24	37,37	14,60	52,16	24,36
Липецкая область	3,63	0,62	37,65	8,61	3,89	43,38
Московская область	22,20	1,84	35,81	11,80	19,33	55,74
Орловская область	4,40	0,48	17,52	22,10	16,49	22,55
Рязанская область	12,08	1,23	15,74	11,96	8,54	13,64
Смоленская область	58,84	2,84	32,29	17,16	18,82	45,31
Тамбовская область	2,76	2,99	15,44	0,20	29,78	9,65
Тверская область	7,22	0,20	15,66	1,01	14,81	11,19
Тульская область	7,67	4,41	7,85	5,22	4,65	29,17
Ярославская область	3,14	0,53	11,49	4,45	25,02	15,09
Москва	55,74	1,22	80,41	36,44	21,56	75,62

ТАБЛИЦА II. Показатели импортозамещения регионов GФО в 2019 г.

Регион	**1**	**2**	**3**	**4**	**5**	**6**
ПФО	**4,02**	**0,26**	**10,40**	**4,64**	**7,00**	**16,24**
Республика Башкортостан	2,16	0,07	2,99	1,04	5,33	12,94
Республика Марий Эл	3,36	0,37	9,79	1,01	4,35	4,96
Республика Мордовия	0,34	0,00	6,20	0,52	5,11	8,40
Республика Татарстан	1,81	0,46	9,77	3,60	10,53	22,21
Республика Удмуртия	1,65	0,35	9,21	2,32	2,88	8,61
Республика Чувашия	0,95	0,00	24,18	0,56	5,77	4,43
Пермский край	2,57	0,08	3,22	0,57	4,85	24,22
Кировская область	0,44	6,29	16,04	0,31	4,88	12,95
Нижегородская область	11,26	0,23	25,04	11,82	6,13	20,25
Оренбургская область	3,47	0,13	10,47	29,29	1,92	34,32
Пензенская область	2,05	1,09	16,47	7,71	8,27	10,95
Самарская область	5,16	0,41	10,19	25,82	16,83	14,04
Саратовская область	10,46	0,22	5,74	7,99	8,77	14,46
Ульяновская область	1,21	0,32	42,87	3,02	10,90	12,65

Далее, для того, чтобы понять, в каком из регионов Российской Федерации уровень импортозамещения выше, а в каком ниже, необходимо визуализировать импортозависимость регионов с помощью дендрограмм.

В данной работе был задействован восходящий подход, при котором в начале каждый субъект Федерации помещался в отдельный кластер, а затем кластеры укрупнялись до тех пор, пока все объекты выборки не попали в одни. В качестве функции расстояния между регионами использовалась евклидова метрика. Построение дендрограмм осуществляется с использованием метода Варда, который отличается от других оценкой расстояний между кластерами с задействованием дисперсионного анализа. Метод минимизирует сумму квадратов для любых двух кластеров, которые могут быть сформированы на каждом шаге. Подробное описание методики можно найти в работе Варда 1963 года «Иерархическая группировка для оптимизации целевой функции» [12]. В целом метод представляется очень эффективным, однако он стремится создавать кластеры малого размера.

Для более наглядной визуализации результатов, а также с целью анализа регионов внутри федеральных округов, на рис. 1–2 представлены данные иерархической кластеризации по Приволжскому и Центральному федеральным округам. Длина вертикальных линий на дендрограмме – это евклидово расстояние между регионами взятое по всем 6 факторам. Чем раньше (ниже на дереве) происходит слияние регионов, тем больше похожи группы наблюдений друг на друга. Наблюдения, которые сливаются позже (возле верхушки дерева), могут сильно отличаться по набору факторов анализа. Высота этой точки слияния, измеренная по вертикальной оси, указывает, насколько разнятся регионы внутри федерального округа.

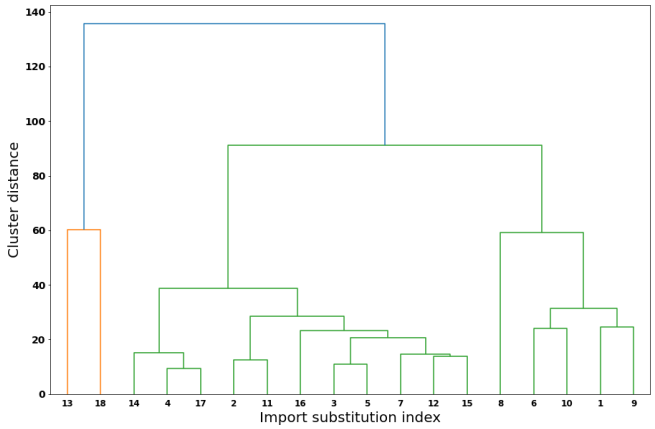

Рис. 1. Кластерный анализ регионов ЦФО

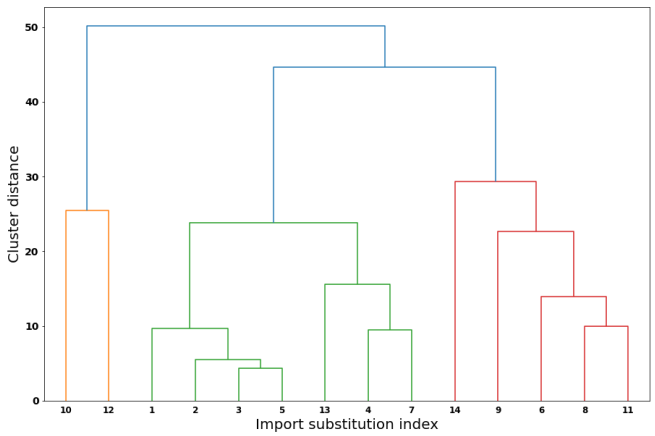

Рис. 2. Кластерный анализ регионов ПФО

Анализируя данные численного эксперимента можно сделать следующие выводы:

1. В результате расчетов получены разбиения регионов на кластеры, где по оси абсцисс отражены регионы, а по оси ординат - значения индекса импортозамещения, представленного многомерной статистической оценкой, сформированной на основе 6 показателей.
2. Иерархическая кластеризация регионов по уровню импортозамещения позволила построить последовательности вложенных кластеров, которые удобно визуализировать с помощью дерева или иерархии кластеров.
3. Динамический анализ показал перманентные изменения состава и структуры кластеров как внутри федеральных округов, так и в РФ в целом.
4. При выборе других критериев связи (дальнего соседа, ближнего соседа, метод центроидов) и методов расчета расстояния (манхэттенское расстояние и др.) в некоторых случаях состав кластеров в значительной степени менялся.
5. Используя тот же алгоритм, в работе был проведен вычислительный эксперимент по всем субъектам Российской Федерации за рассматриваемые три года. Расчеты показали, что количество кластеров, на которые разбиваются субъекты Федерации за указанные три года разные. При этом, наиболее целесообразным является разбиение исходного множества в 2010 году на 2 кластера, в 2015 году на 3 кластера, а в 2020 году снова на 2 кластера. Процесс объединения кластеров показывает, какие регионы наиболее близки по заданному набору факторов.

Кластерный анализ, проведенный в ходе данного исследования, позволил сгруппировать регионы по уровню импортонезависимости (импортозависимости), а также проанализировать современное состояние и тенденции развития уровня показателей импортозамещения.

V. Выводы

Таким образом, в данной работе описывается модель кластеризации субъектов Федерации по уровню зависимости от импорта, основанная на иерархических процедурах кластеризации. Предложена система показателей кластеризации, для формирования которых формировались массивы данных, полученных из официальных статистических источников и отражающих товарную структуру внешнеэкономической деятельности России. Вычислительный эксперимент наглядно продемонстрировал региональный уровень импортозамещения в Центральном и Приволжском федеральных округах, а также показал восходящий порядок формирования кластеров.

Список литературы

[1] Безпалов В.В. Импортозамещение: анализ подходов к определению понятия // Управление экономическими системами: электронный научный журнал. 2016. №11 (93) URL: https://cyberleninka.ru/article/n/importozameschenie-analiz-podhodov-k-opredeleniyu-ponyatiya

[2] Алѐхина Т.А., Захаркина Н.В. Импортозамещение как основной инструмент развития экономики России. // Вестник Дагестанского государственного технического университета. Технические науки. 2018;45(1):223-235. https://doi.org/10.21822/2073-6185-2018-45-1-223-235

[3] Ямашкина Е.О., Ямашкин С.А., Платонова О.В., Коваленко С.М. Разработка нейросетевой модели для анализа пространственных данных // Russian Technological Journal. 2022;10(5):28-37. https://doi.org/10.32362/2500-316X-2022-10-5-28-37

[4] Анфёров М.А. Генетический алгоритм кластеризации // Russian Technological Journal. 2019;7(6):134-150. https://doi.org/10.32362/2500-316X-2019-7-6-134-150

[5] Дударин П.В., Ярушкина Н.Г. Подходы к нечеткой и иерархической кластеризации и классификации ключевых показателей эффективности системы стратегического планирования российской федерации // Нечеткие системы, мягкие вычисления и интеллектуальные технология (НСМВИТ-2017): труды VII всероссийской научной-практической

конференции. 2017. Том. 2. С. 65–73. https://elibrary.ru/item.asp?id=30320069

[6] Верхорубов А.И., Жуков В.Г. О решении задачи кластерного анализа инцидентов информационной безопасности // Решетневские чтения. 2011. №15. URL: https://cyberleninka.ru/article/n/o-reshenii-zadachi-klasternogo-analiza-intsidentov-informatsionnoy-bezopasnosti

[7] Федеральная служба государственной статистики. Electronic resource. URL: https://rosstat.gov.ru/

[8] Казанцев С.В., Митяков Е.С. Оценка значимости факторов динамики жизнеспособности субэктов Российской Федерации // *Экономическая безопасность.* 2022. Т. 5. № 1. с. 155-174. doi: 10.18334/ecsec.5.1.114267

[9] Жамбю М. Иерархический кластер-анализ и соответствия / Пер. Б.Г. Миркин. М.: Финансы и статистика. 1988. 345 с.

[10] Классификация и кластер / ред. Райзин, Дж. Вэн. М.: Мир, 1980. 390 с.

[11] Ward J.H., Jr. (1963), "Hierarchical Grouping to Optimize an Objective Function", Journal of the American Statistical Association, 58, pp. 236–244.

[12] Евстифеев А.А. Системный анализ поддержки принятия решений при развитии сети газовых заправочных станций // Вестник Тамбовского государственного технического университета. 2021. Т. 27. № 2. С. 203-211. DOI 10.17277/vestnik.2021.02.pp.203-211.

[13] Kraufman, L., Rousseeuw, P. (2005). Finding groups in Data. An Introduction to Cluster Analysis. Wiley. DOI: http://dx.doi.jrg/10.1002/9780470316801.ch1

Организация хранения данных для проведения дополнительной диагностики работы при мониторинге компьютерной сети

М. И. Авилов
Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» им. В.И. Ульянова (Ленина)
miavilov@etu.ru

Аннотация. **Рассматриваются вопросы хранения данных системы мониторинга компьютерной сети для проведения дополнительной диагностики в случаях выявления аномалий в работе такой сети. Предлагается раздельное хранение данных для проведения дополнительной диагностики работы компьютерной сети и данных о состоянии всех наблюдаемых узлах компьютерной сети. Раздельное хранение статистических данных о состоянии и данных для осуществления воздействия на наблюдаемый узел позволяет накапливать базу положительно сработавших сценариев по устранению выявленных аномалий в работе компьютерной сети. Такое накопление позволяет использовать базу данных сценариев при мониторинге схожих компьютерных сетей.**

Ключевые слова: система мониторинга компьютерной сети; база данных; компьютерная сеть; аномалии компьютерной сети

I. Введение

С каждым годом актуальность применения систем мониторинга компьютерной сети растет. Такие системы позволяют обеспечивать производительность и надежность работы компьютерных сетей. Они позволяют оперативно реагировать на возникающие проблемы и своевременно исправлять их. Без них невозможно представить современную сложную сетевую инфраструктуру, в которую входят сотни серверов, сетевых устройств и пользователей. В тоже время, развитие систем мониторинга компьютерных сетей не стоит на месте и будет продолжаться, по мере того как сети будут становиться более сложными и распределенными. За последние десять лет запросы в поисковых системах по различным системам мониторинга сетевой инфраструктуры значительно выросли [1]. Динамика изменения числа запросов в некоторых распространенных системах показана на рис. 1.

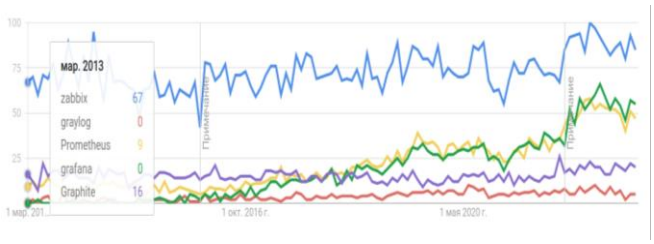

Рис. 1. Рост запросов в поисковой системе Google по система Zabbix, Graylog, Prometeus, Grafana, Graphite за десять лет

Одной из важных задач системы мониторинга компьютерной сети является своевременное обнаружение проблем и аномалий в сети. Если такие ситуации не обнаруживать вовремя, то это может привести к сбоям, которые повлияют на производительность и надежность работы сети. Часто системные инженеры организуют проведение дополнительной диагностики с целью выявления проблем и аномалий в сети путем комбинирования нескольких систем мониторинга сети или разрабатывают собственные модули дополнительной диагностики работы компьютерной сети. Проведение дополнительной диагностики проблем и аномалий в работе компьютерной сети позволяет своевременно выявлять нестабильные компоненты сети и оперативно устранять причины возникших ситуаций. Для проведения такой дополнительной диагностики аномалий в работе компьютерной сети данные могут храниться в единой базе данных или в отдельной базе данных. Выбор способов хранения данных системы мониторинга сети зависит от решений по организации мониторинга компьютерной сети. Данное исследование является продолжением исследований [2–3], в котором рассматривается возможность раздельного хранения данных для мониторинга компьютерной сети и данных для проведения дополнительной диагностики возникшей проблемной ситуации в работе компьютерной сети.

II. Анализ существующих решений и постановка задачи

Существует много различных решений по реализации систем мониторинга компьютерной сети. В работе [4] авторы предлагают алгоритм машинного обучения, реализующий интеллектуальный мониторинг сетей беспроводной связи. Предлагаемая интеллектуальная система мониторинга уязвимостей безопасности компьютерной сети основывается на традиционной системе мониторинга уязвимостей беспроводной сети. Экспериментальная часть исследования проводилась на платформе Matlab и хранение данных осуществлялось также в этой системе.

В [5] предлагается функциональная схема системы диагностики «здоровья» компьютерной сети на основе анализа собранных исторических данных значимых параметров, определяющих состояние компьютерной сети. Статистические данные собираются системой мониторинга компьютерной сети в базу данных, и далее происходит обучение через изучение разных аномальных симптомов в исторических данных, на основе которых осуществляется прогнозирование ситуаций в будущем.

Анализ возможностей автоматизации контроля состояния компьютерных систем, при помощи специального интеллектуального анализа неструктурированных данных из системных журналов, отражен в работе [6]. Авторы описывают этапы такой автоматизации контроля работы сети. Журналы событий передаются системе мониторинга в базу данных, а в качестве метода классификации используется дерево принятия решений при машинном обучении выявления аномалий сети.

А работе [7] предлагается модель прогнозирования отказов оборудования на основе машинного обучения. Применяется алгоритм Random Forest. Такая модель состоит из нескольких подмоделей. Эти подмодели прогнозируют отказ оборудования, используя фактические данные и прогнозируемые данных, полученные с датчиков на наблюдаемых объектах. Данные собирается в базу данных. Далее происходит обучение на нормальных данных и настройка на данных, которые отражают предыдущие поломки.

Актуальность применения проактивного мониторинга в управлении ИТ-системами отражена в работе [8]. Авторы отмечают, что не существует обобщенной модели, позволяющей решить любую задачу прогнозирования событий, а также формулируются предложения для реализации концептуальной модели проактивного мониторинга ИТ-систем. Выбор систем управления базами данных зависит от правильно выбранного набора данных, как отмечают авторы. Состояние самих же баз данных также требует наблюдения, чтобы отслеживать их производительность. Это связано с тем, что производительность обработки данных влияет на производительность всей системы мониторинга сетевой компьютерной инфраструктуры.

Мониторинг беспроводных сетей 5G с целью выявления аномалий в работе таких сетей описан в [9]. Авторы предлагают архитектуру системы киберзащиты, ориентированную на 5G. Такая архитектура использует методы глубокого обучения для анализа сетевого трафика путем извлечения особенностей из сетевых потоков. Собираются статистические данные, которые отражается состояние компьютерной сети, и записываются в базу данных. Далее при помощи обученной искусственной нейронной сети определяются симптомы аномалий в трафике сети, после чего эти симптомы передаются для анализа ситуации в специальный модуль, определяющий является ли текущая ситуация аномальной или нет.

Модель интеллектуального мониторинга состояния работы сетевого оборудования на основе SNMP (Simple Network Management Protocol – простой протокол сетевого управления) предлагается в работе [10]. Автор отмечает, что такая модель позволяет осуществлять выявление неполадок при помощи экспертной модуля, который работает с историческими данными, собранными с наблюдаемых устройств при помощи SNMP. Сами же данные хранятся в базе данных, к которой обращается экспертный модуль системы мониторинга компьютерной сети. После анализа полученных данных экспертный модуль передает соответствующую информацию о состоянии компьютерной сети на дисплей устройства, монитор компьютера системного инженера. Предлагаемая модель позволяет в режиме реального времени отслеживать состояние наблюдаемых сетевых устройств.

Комплексная модель повышения эффективности пропускной способности на основе мониторинга входящих и исходящих пакетов описывается в [11]. Авторы отмечают, что представленная модель иллюстрирует использование и потенциальное применение инструмента анализа сети в многокомпьютерной системе любого масштаба. Эта модель основана на архитектуре клиент-сервер и использует удаленный доступ для мониторинга и обслуживания сетевых наблюдаемых устройств. Вся информация, собранная системой мониторинга работы сети, сохраняется в единую базу данных при помощи MySQL. Это позволяет системному инженеру просматривать информацию о производительности наблюдаемого сетевого узла, загруженность сетевых каналов и изучать другие данные о состоянии наблюдаемых узлов.

Проведенный анализ смежных работ в данной области показывает, что существует множество различных моделей систем мониторинга сетевой компьютерной инфраструктуры, как с применением искусственных нейронных сетей, так с применением экспертных систем и систем с шаблонами действий. Однако для проведения дополнительной диагностики аномалий в работе компьютерной сети во многих случаях используется одна база данных, где хранится, как собранная информация, так и информация для дополнительной диагностики работы сети. Такое хранения данных может негативно сказаться на вычислительной производительности системы мониторинга сети.

Целью проводимых исследования являлась оценка возможностей раздельного хранения данных при проведении дополнительной диагностики аномалий в работе компьютерной сети. Для этого было осуществлено разделение хранения данных для всех наблюдаемых сетевых узлов и данных, необходимых для проведения дополнительной диагностики аномалий в работе компьютерной сети.

III. Раздельно хранение данных для проведения дополнительной диагностики аномалий при мониторинге компьютерной сети

В рамках проводимых исследований отдельная база данных нужна для хранения сформированных рабочих сценариев. Рабочие сценарии формируются при проведении дополнительной диагностики аномалии в работе компьютерной сети по результатам воздействия на наблюдаемый объект. Подробнее про дополнительную диагностику аномалий в работе компьютерной сети и про рабочие сценарии было описано в [2–3]. Взаимодействие модулей системы мониторинга компьютерной сети и модуля дополнительной диагностики аномалий работы компьютерной сети с базами данных отражено на рис. 2.

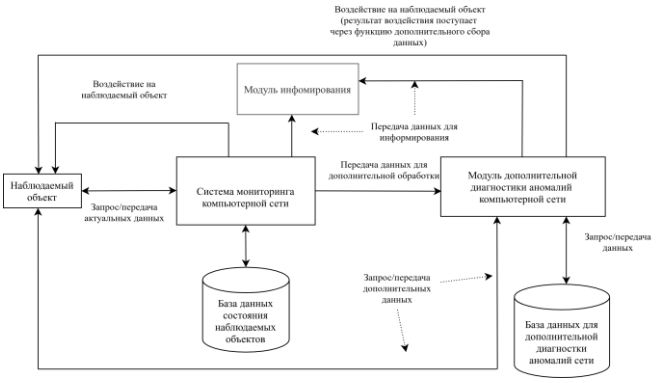

Рис. 2. Схема системы мониторинга компьютерной сети с модулем дополнительной диагностики аномалий

Сначала система мониторинга компьютерной сети собирает данные с наблюдаемого узла. Если необходима дополнительная диагностика возникшей ситуации в сети, то запускается модуль дополнительная диагностика аномалий в работе компьютерной сети, иначе осуществляется информирование системного инженера о состоянии наблюдаемого узла. Такой модуль собирает дополнительные данные для оценки состояние наблюдаемого объекта и осуществляет воздействие на наблюдаемый объект при помощи вспомогательного инструментария, который заранее определил системный инженер. В случае успешного воздействия фиксируется рабочий сценарий и записывается в базу данных для дополнительной диагностики аномалий сети. По результатам проведенных действий осуществляется информирование системного инженера о состоянии наблюдаемого узла. На рис. 3 и 4 показаны замеры скорости чтения и записи в единую базу данных и отдельную базу данных для дополнительной диагностики аномалий в работе компьютерной сети.

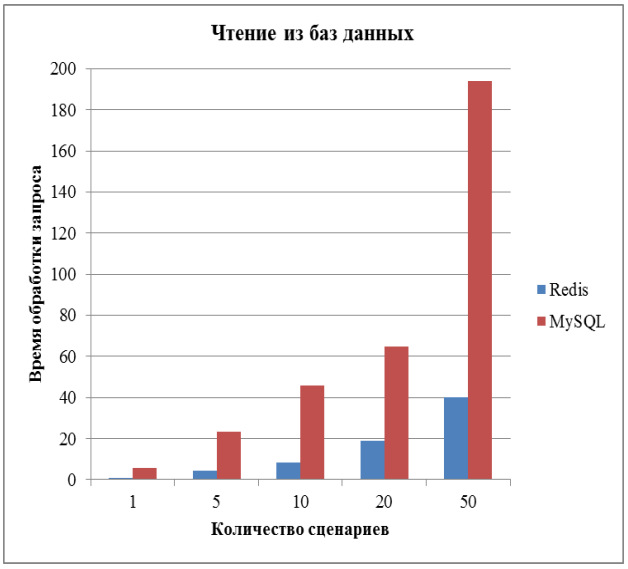

Рис. 3. Сравнения замеров скорости чтения из единой базы данных и отдельной базы данных для дополнительной диагностики аномалий в работе компьютерной сети

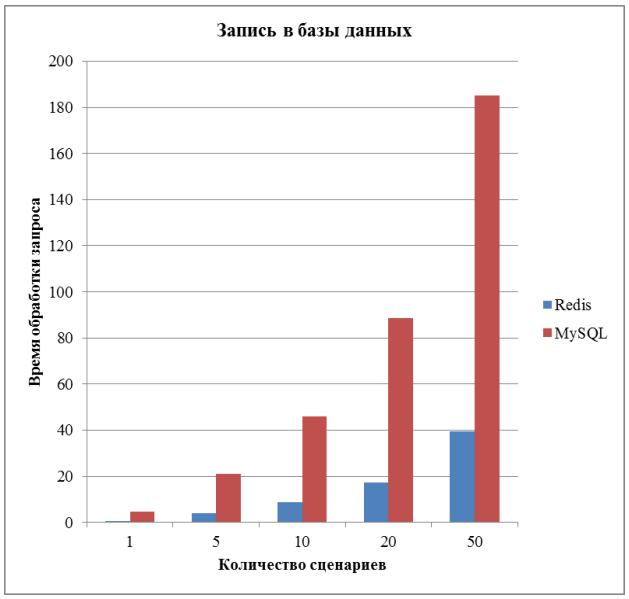

Рис. 4. Сравнения замеров скорости записи в единую базу данных и отдельную базу данных для дополнительной диагностики аномалий в работе компьютерной сети

Тестовые замеры производились в виртуальной машине на сервере со следующими характеристиками:

- операционная система Debian 11, x86_64 Linux 5.10.0-16-amd64;
- центральный процессов Intel Core i7-7700 3,599GHz;
- оперативная память 2048 МБ;
- жесткий диск 20 ГБ.

В качестве основной системы мониторинга компьютерной сети по сбору данных является Zabbix и с этой системой по умолчанию применяется MySQL, поэтому в тестовых замерах участвует MySQL. Так как хранение данных в базе данных для дополнительной диагностики аномалий в работе компьютерной сети организуется отдельно и сами рабочие сценарии с технической стороны представляют набор символов для их дальнейшей обработки, то для хранения таких данных в виде «ключ-значение» была выбрана Redis. Выборка сценария происходила, как для MySQL, так и для Redis в формате «номер сценария – сам сценарий».

По результатам замеров видно, что при работе с отдельной базой данных через Redis скорость обработки запросов на чтение/запись, при увеличении количества рабочих сценариев, значительно ниже, чем при работе с единой базой данных через MySQL. Применение Redis возможно из-за особенностей формирования рабочих сценариев в формате «номер сценария – сам сценарий». Обработка самого сценария происходит на сервере и не требует дополнительных запросов в отдельную базу данных, таких как формирование специальных SQL-запросов на выборку данных из таблицы.

IV. Заключение

В результате проведенного исследования была рассмотрена возможность раздельного хранения данных о состоянии всех наблюдаемых узлов и данных, необходимых для проведения дополнительной диагностики аномалий в работе компьютерной сети. Данное исследование является продолжением исследований [2–3]. Проанализированы существующие решения по вопросу раздельного хранения данных в системах мониторинга компьютерной сети. Предложена схема взаимодействия модулей системы мониторинга компьютерной сети с раздельными базами данных.

Проведенные эксперименты показывают, что за счет разделения хранения данных возможно применять различные способы хранения этих данных. В рамках исследования удалось увеличить скорость обработки запросов к данным, для проведения дополнительной диагностики аномалий в работе компьютерной сети, за счет хранения данных по дополнительной диагностики сети в отдельной базе данных, которая работает по принципам NoSQL.

Список литературы

[1] Динамика популярности систем Zabbix, Graylog,Prometheus,Grafana,Graphite за десять лет в поисковой системе Google [Электронный ресурс]. URL: https://trends.google.ru/trends/explore?date=2013-03-01%202023-03-01&geo=RU&q=zabbix,graylog,Prometheus,grafana,Graphite&hl=ru (дата обращение 06.03.23).

[2] Авилов М.И., Шичкина Ю.А., Куприянов М.С. Мониторинг информационно-коммуникационной компьютерной сети с применением модуля дополнительной диагностики // Известия СПбГЭТУ "ЛЭТИ". СПб. 2020. №5. С. 34–45.

[3] Авилов М.И., Шичкина Ю.А. Дополнительная диагностика аномалий при мониторинге динамической компьютерной сети с применением рабочих сценариев // Известия СПбГЭТУ "ЛЭТИ". СПб. 2021. №10. С. 94–102.

[4] Исобоев Ш.И., Везарко Д.А., Чечельницкий А.С. Интеллектуальная система мониторинга безопасности сети беспроводной связи на основе машинного обучения // Экономика и качество систем связи. 2022. №1 (23). С. 44–48.

[5] Шелухин О.И., Осин А.В., Костин Д.В. Мониторинг и диагностика аномальных состояний компьютерной сети на основе изучения исторических данных // T-Comm - Телекоммуникации и Транспорт. Москва. 2020. №4. С. 23–30.

[6] Шелухин О.И., Рябинин В.С., Фармаковский М.А. Обнаружение аномальных состояний компьютерных систем средствами интеллектуального анализа данных системных журналов // Вопросы кибербезопасности. Москва. 2018. №2 (26). С. 33–41.

[7] Шаханов Н.И., Варфоломеев И.А., Ершов Е.В., Юдина О.В. Прогнозирование отказов оборудования в условиях малого количества поломок // Вестник Череповецкого государственного университета. Череповец. 2016. №6 (75). С. 36–41.

[8] Дубровин М.Г., Глухих И.Н. Модели и методы проактивного мониторинга ИТ-систем // Моделирование, оптимизация и информационные технологии. Воронеж. 2018. Т. 6. № 1. С. 314-324.

[9] Fernandez Maimo L., Perales Gomez A. L., Garcia Clemente F. J., Gil Perez M., Martinez Pérez G. A Self-Adaptive Deep Learning-Based System for Anomaly Detection in 5G Networks // Cyber Physical Social Computing and Networkingin in IEEE Access, vol. 6, P. 7700-7712, 2018, doi: 10.1109/ACCESS.2018.2803446.

[10] J. Zhang Design and implementation of test IP network intelligent monitoring system based on SNMP // 2017 IEEE 2nd Advanced Information Technology, Electronic and Automation Control Conference (IAEAC), Chongqing, China, 2017, P. 2124-2127, doi: 10.1109/IAEAC.2017.8054392.

[11] Mr.Sanjay Tiwari, Rajendra singh Network Analysis and Remote Monitoring control System Software based on Client - Server Architecture // GADL Journal of Inventions in Computer Science and Communication Technology. Vol. 2018 P. 8-14.

FPGA-реализация деления чисел с фиксированной точкой методом Ньютона–Рафсона

О. И. Буренева[1], О. Ю. Кайданович[2]
[1] *Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» им. В.И. Ульянова (Ленина)*
[2] *Некоммерческое акционерное общество «Карагандинский технический университет имени Абылкаса Сагинова»*
OIBureneva@etu.ru

***Аннотация*. В работе приводятся результаты имплементации алгоритмов деления на ПЛИС. Рассмотрены алгоритм деления без восстановления остатка и алгоритм, основанный на методе деления Ньютона–Рафсона. Определены аппаратные затраты на реализацию, рассчитаны временные характеристики, показавшие преимущества аппаратной реализации метода Ньютона–Рафсона. Проведено сравнение с выполнением операции деления с использованием библиотечных модулей САПР Quartus Prime, подтвердившее эффективность алгоритмических решений.**

Ключевые слова: быстрые арифметические операции; операция деления; деление числе с фиксированной точкой; реализация на ПЛИС; алгоритм Ньютона–Рафсона

I. Введение

При реализации искусственных нейросетей различного типа всегда возникает задача выполнения арифметических операций, из которых наиболее сложной является деление. Оно необходимо, например, при расчете сигмоидной функции в многослойных персептронах [1, 2], для оценки относительной количественной меры сходства в сетях адаптивной резонансной теории [3] и др. При этом важным параметром операции является скорость ее выполнения.

Перспективной элементной базой для аппаратной реализации нейронных сетей являются программируемые логические интегральные схемы (ПЛИС), обеспечивающие естественный параллелизм обработки данных. Кроме того, ПЛИС с архитектурой FPGA (Field-Programmable Gate Array) имеют в своем составе специализированные ресурсы, ориентированные на выполнение арифметических операций [4]. Несмотря на наличие встроенных ЦОС блоков, часто возникает необходимость разработки аппаратных ускорителей для выполнения арифметических операций. Это объясняется тем, что универсальные библиотечные модули зачастую имеют не самые высокие характеристики [5, 6]. Особенно это проявляется тогда, когда разрядность обрабатываемых данных не соответствует размерам встроенных арифметических блоков, конфигурируемых как 9×9-, 18×18- и 36×36-битные [7]. В реальных же задачах встречаются аргументы с разрядностями от 16 до 128 бит и выше. В связи с этим актуальной является разработка эффективных алгоритмов выполнения операций с числами большой разрядности [8].

Известен ряд алгоритмов операции деления для разных типов операндов. В [9] рассмотрены варианты быстрых ведических делителей, делителей на основе алгоритма Гольдшмидта [10]. Авторы [11] предложили архитектуру блока делителя с использованием предварительно вычисленных значений. В [12] показан вариант делителя с использованием алгоритма CORDIC.

Для классических алгоритмов целочисленного деления с восстановлением и без восстановления остатка разработаны различные методы ускорения. В этих методах оптимизация может касаться операции суммирования/вычитания при вычислении частичных остатков, для чего применяются быстрые схемы сложения с использованием различных приемов ускорения переноса. Также возможна минимизация количества операций суммирования/вычитания при расчете значения частного остатка.

Кроме оптимизации классических методов деления разработаны оригинальные быстрые алгоритмы:

- варианты алгоритма авторов Sweeney, Robertson, Tocher (SRT) [13], являющиеся модификацией деления без восстановления остатка, в которых сложение или вычитание в зависимости от получающегося частного остатка на некоторых шагах не выполняется, что позволяет минимизировать время выполнения операции;
- алгоритмы, основанные на применении избыточных систем счисления при вычислении частного;
- алгоритм Голдшмита [14], в котором операция деления правильных дробей сводится к последовательным операциям умножения числителя и знаменателя на постоянные коэффициенты, что не изменяет соотношение, но позволяет привести знаменатель к единице;
- алгоритм Ньютона–Рафсона [15] заключается в замене операции деления на умножение делимого на величину, обратную делителю, что приводит к задаче вычисления обратной величины.

Работа выполнена при поддержке Минобрнауки России в рамках соглашения № 075-15-2020-933 от 13.11.2020 г о предоставлении гранта в форме субсидий из федерального бюджета на осуществление государственной поддержки создания и развития научного центра мирового уровня «Павловский центр «Интегративная физиология – медицине, высокотехнологичному здравоохранению и технологиям стрессоустойчивости».

Целью данной работы являлась аппаратная реализация устройства деления на базе метода Ньютона–Рафсона и его сравнение с альтернативными вариантами, ориентированными на имплементацию в ПЛИС.

II. Метод деления Ньютона–Рафсона

Идея метода деления Ньютона–Рафсона состоит в замене операции деления на умножение делимого на величину, обратную делителю:

$$Y = \frac{A}{D} = A\,\frac{1}{D}, \tag{1}$$

при этом обратная величина может быть вычислена итеративным методом нахождения корня уравнения

$$F(x) = \frac{1}{x} - D.$$

Итеративное уравнение Ньютона-Рафсона имеет вид

$$x_{i+1} = x_i - \frac{F(x_i)}{F'(x_i)} = x_i - \frac{\frac{1}{x_i} - D}{-\frac{1}{x_i^2}} = x_i(2 - x_i D). \tag{2}$$

После некоторого конечного количества итераций уравнение (2) сходится к обратной величине 1/D. Важным для эффективной работы алгоритма является выбор начального значения x_0, которое определяет характеристики сходимости. Значение D необходимо отмасштабировать так, чтобы оно находилось в диапазоне $0{,}5<D\leq 1$, в этом случае алгоритм сходится максимально быстро: 32-битный результат можно получить за 4 итерации. Чтобы привести значение D в заданный диапазон достаточно воспользоваться операцией сдвига, причем сдвиг может быть как вправо, так и влево. В этом интервале необходимо выбрать начальное значение x_0, для чего используется следующая формула:

$$x_0 = \frac{48}{17} - \frac{32}{17}D.$$

На каждой итерации метода число верных знаков в результате удваивается, что важно при работе с числами больших разрядностей. В зависимости от выполненного сдвига делителя необходимо произвести сдвиг делимого, чтобы получить верный результат операции.

Таким образом, метод предполагает выполнение следующих действий:

- сдвиг аргумента для его приведения к диапазону [0.5,1];
- расчет начального значения x_0;
- выполнение итераций Ньютона–Рафсона;
- умножение делимого на число, обратное делителю;
- масштабирование (сдвиг) результата с учетом направления и количества сдвигов, выполненных на первом этапе.

Устройство, выполняющее вычисления по приведенному алгоритму, может быть выполнено как в последовательном варианте, так и с параллельной реализацией некоторых операций. Возможна организация конвейерной обработки.

III. Аппаратная реализация метода

Описание устройства выполнено на языке проектирования аппаратуры VerilogHDL. Проектирование устройства выполнялось с учетом его дальнейшей имплементации в программируемые логические интегральные схемы. RTL представление устройства, сгенерированное системой проектирования Quartus Prime с выбором микросхемы Cyclone 10LP, приведено на рис. 1.

В реализации использованы регистры защелки DFF_rg:reg1 и DFF_rg:reg2 для хранения аргументов операции на время выполнения вычислений, а также регистр для фиксации результата DFF_rg:reg3, умножитель Mult0 для выполнения операции (1), а также оформленное в виде отдельного модуля нижнего уровня иерархии устройство вычисления обратной функции по формуле (2) NRD:NRD_inst.

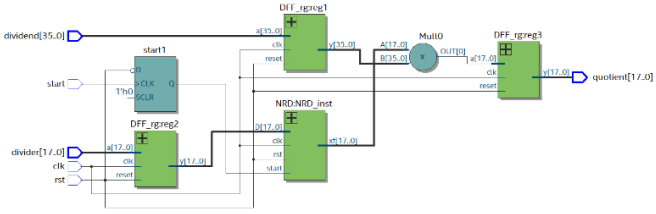

Рис. 1. RTL устройства деления методом Ньютона–Рафсона

RTL представление устройства вычисления обратной функции приведено на рис. 2.

В ходе исследований было проведено сравнение спроектированного устройства с устройством, реализующим классический алгоритм деления без восстановления остатка, а также делителем, созданным с использованием библиотечных модулей LPM_divider. Результаты сравнения аппаратных затрат и временных характеристик 18-ти разрядных устройств приведены в табл. I. Анализ данных таблицы показывает, что аппаратные затраты на реализацию устройства деления на базе библиотечной функции значительно превышают затраты при делении альтернативными алгоритмами. Реализация метода Ньютона–Рафсона более экономична в части логических ячеек и регистров по сравнению с алгоритмом деления без восстановления остатка, однако для такой реализации дополнительно потребовались встроенные умножители.

Частотные характеристики устройств отличаются значительно, причем алгоритмические реализации обладают существенным преимуществом.

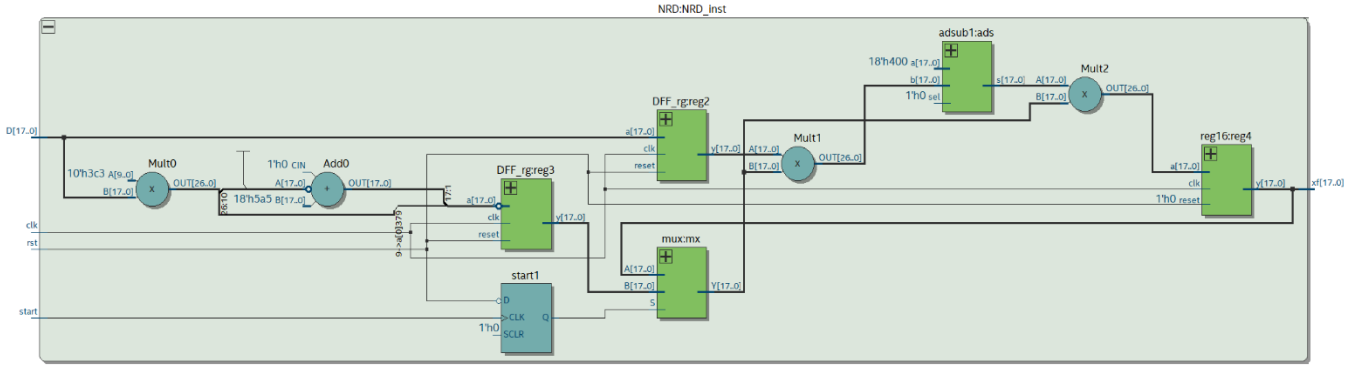

Рис. 2. RTL Вычислителя обратной функции

В табл. I приведены максимально возможные частоты тактового сигнала Fmax, рассчитанные с использованием модели Slow1. Эта модель соответствует худшим параметрам эксплуатации (напряжение – 1200 мВ, температура – 85 °C), учитываемым при выполнении статического временного анализа. Выполнялся расчет самого низкого быстродействия для различных путей, модель построена для микросхемы с наихудшим быстродействием. При сравнении частотных характеристик устройств необходимо учитывать тот факт, что количество итераций традиционного алгоритма определяется разрядностями аргументов, в то время как алгоритм Ньютона–Рафсона при использовании масштабирования аргументов сходится за 4–5 итераций.

ТАБЛИЦА I. ХАРАКТЕРИСТИКИ УСТРОЙСТВ ДЕЛЕНИЯ

	Аппаратные затраты			**Fmax**
	Логическ. элементы	***Регист-ры***	***Встроенные умножители***	
LPM_Divider	1039	99	-	17 МГц
Деление без восстановления остатка	101	75	-	233 МГц
Деление методом Ньютона–Рафсона	95	40	9	86 МГц

При недостатке встроенных блоков умножения для проектирования делителей методом Ньютона–Рафсона можно использовать быстродействующие умножители, реализованные на логических ячейках ПЛИС [14].

IV. ЗАКЛЮЧЕНИЕ

При аппаратных решениях вычислительных задач с использованием микросхем программируемой логики, требующих высокого быстродействия для выполнения деления чисел с фиксированной точкой, необходимо использовать специальные быстрые алгоритмы, одним из которых является алгоритм Ньютона–Рафсона. Этот алгоритм обладает высокой сходимостью и позволяет работать с числами с большой разрядностью.

При реализации метода Ньютона–Рафсона использованы логические элементы, регистры и встроенные умножители, которые при необходимости могут быть заменены на модули умножения, также реализованные на логических ячейках ПЛИС.

Производительность рассмотренных делителей может быть увеличена методом конвейеризации, что позволит обрабатывать данные, поступающие непрерывным потоком.

Разработанное описание устройства на языке Verilog обеспечивает легкое масштабирование за счет использования параметров, характеризующих разрядности данных. Делители, реализованные на ПЛИС, могут стать прототипами для проектирования заказных интегральных схем.

СПИСОК ЛИТЕРАТУРЫ

[1] Tsmots I., Skorokhoda O., Rabyk V. Hardware Implementation of Sigmoid Activation Functions using FPGA // 2019 IEEE 15th International Conference on the Experience of Designing and Application of CAD Systems (CADSM), Polyana, Ukraine, 2019, pp. 34–38. DOI:10.1109/CADSM.2019.8779253

[2] Shatravin V., Shashev D., Shidlovskiy S. Sigmoid Activation Implementation for Neural Networks Hardware Accelerators Based on Reconfigurable Computing Environments for Low-Power Intelligent Systems // Applied Sciences. 2022. T. 12. C. 5216. DOI:10.3390/app12105216

[3] Bahoura M., Park C. -W. FPGA-implementation of an adaptive neural network for RF power amplifier modeling // 2011 IEEE 9th International New Circuits and systems conference, Bordeaux, France, 2011, pp. 29–32. DOI: 10.1109/NEWCAS.2011.5981211

[4] Hanyang Xu, Jinmei Lai. A high throughput FPGA embedded DSP architecture design // 2013 IEEE 10th International Conference on ASIC, Shenzhen, China, 2013, pp. 1–4. DOI: 10.1109/ASICON.2013.6811825.

[5] Буренева О.И., Пустовойтова А.А., Соболев Д.М. Аппаратная реализация арифметических операций в автомобильном радаре // Известия СПбГЭТУ «ЛЭТИ». 2020. № 8-9. С. 20–27.

[6] Хорошайлова М.В. Реализации нейронной сети на ПЛИС с использованием аппаратных ресурсов // Вестник воронежского государственного технического университета. 2021. Т. 17, вып. 3. С. 127–134.

[7] Altera, Intel UG-20094 Cyclone 10 GX Native Fixed Point DSP IP Core. User Guide https://www.intel.com

[8] Назаров А.С. Обзор методов выполнения арифметических операций над числами большой разрядности на примере операции деления // Высокопроизводительные параллельные вычисления на кластерных системах. Материалы XIII Всероссийской конференции (Н. Новгород, 14–16 ноября 2013 г.) / Под ред. проф. В.П. Гергеля. Нижний Новгород: Изд-во Нижегородского госуниверситета, 2013, С. 187–190.

[9] Vemula R., Chari K. M. A review on various divider circuit designs in VLSI // 2018 Conference on Signal Processing And Communication Engineering Systems (SPACES), Vijayawada, India, 2018, pp. 206–209. DOI: 10.1109/SPACES.2018.8316347

[10] Tingting He, Jiyang Chen, Yuanwu Lei, Yuanxi Peng, Baozhou Zhu. High-Performance FP Divider with Sharing Multipliers Based on Goldschmidt Algorithm // Chinese Journal of Electronics. 2017. Vol.26, No.2, pp. 292-298. DOI:10.1049/cje.2016.10.004

[11] Muhammad Firmansyah Kasim, Trio Adiono, Muhammad Fahreza, Muhammad Fadhli Zakiy. FPGA Implementation of Fixed-Point Divider Using Pre-Computed // 4th International Conference on Electrical Engineering and Informatics (ICEEI 2013), Bandung, Indonesia, 2013 / Procedia Technology. № 11. С. 206–211. DOI: 10.1016/j.protcy.2013.12.182

[12] Dong Wang, Pengju Ren, Leibo Liu. A high-throughput fixed-point complex divider for FPGAs // IEICE Electronics Express. 2013. № 10(4):20120879-20120879. DOI: 10.1587/elex.10.20120879

[13] Russinoff D.M. A Mechanically Verified Commercial SRT Divider. In: Hardin, D. (eds) Design and Verification of Microprocessor Systems for High-Assurance Applications. Springer, Boston, MA. DOI:10.1007/978-1-4419-1539-9_2

[14] Singh N., Sasamal T. N. Design and synthesis of goldschmidt algorithm based floating point divider on FPGA // 2016 International Conference on Communication and Signal Processing (ICCSP), Melmaruvathur, India, 2016, pp. 1286-1289. DOI: 10.1109/ICCSP.2016.7754360

[15] Pandey P.K., Singh D., Chandel R. Fixed-Point Divider Using Newton Raphson Division Algorithm. In: Nath, V., Mandal, J.K. (eds) Proceeding of Fifth International Conference on Microelectronics, Computing and Communication Systems. Lecture Notes in Electrical Engineering, vol 748. Springer, Singapore. DOI:10.1007/978-981-16-0275-7_19

[16] Миронов С.Э., Буренева О.И., Зибарев К.М. Быстродействующие умножители для аппаратной реализации искусственных нейронных сетей // Проблемы разработки перспективных микро- и наноэлектронных систем (МЭС). 2022. Выпуск 4. С. 109–116. DOI:10.31114/2078-7707-2022-4-109-116

Интеллектуальная информационная система и база знаний сушильных установок

С. В. Артемова[1], А. И. Ладынин[2],
Н. М. Шмелева[3], М. И. Бесхмельнов[4]
МИРЭА – Российский технологический университет
[1]sartemova@mail.ru, [2]andrey.ladynin@hotmail.com,
[3]nina.sh.02@mail.ru , [4]m_beskhmelnov@mail.ru

М. А. Каменская
Тамбовский государственный технический университет
art_mari@bk.ru

***Аннотация*. Процессы сушки играют решающую роль в различных отраслях промышленности, таких как пищевая, фармацевтическая и химическая, где жизненно важны эффективность, энергосбережение и качество продукции. В этой статье представлена интеллектуальная информационная система контроля и управления для оптимизации процессов сушки, интеграции датчиков, контроллеров и алгоритмов искусственного интеллекта для мониторинга, оптимизации и автоматизации этих процессов. Система обеспечивает сбор данных в режиме реального времени, адаптивное обучение, профилактическое обслуживание и совместима с другими ранее развернутыми системами. Используя алгоритмы искусственного интеллекта, такие как искусственные нейронные сети и обучение с подкреплением, система обеспечивает экономию энергии, повышение качества продукции и минимизацию человеческих ошибок. Интеллектуальная система представляет собой ценное решение для отраслей, стремящихся усовершенствовать свои процессы сушки, снизить затраты и поддерживать высокие стандарты качества.**

Ключевые слова: информационная система, база знаний оценка влажности материала, состояния функционирования, нейронные сети

I. Введение

Алгоритмы искусственного интеллекта в управлении технологическими процессами в настоящее время используют нейронные сети для моделирования сложных закономерностей в данных [1]. Современные информационные системы позволяют улучшить различные задачи анализа данных, обеспечивая поддержку принятия решений и рост производительности [2]. Сушка – это широко распространенный процесс в различных отраслях промышленности и сельского хозяйства. Отличительной особенностью, которого является его энергоемкость, поэтому управление процессом сушки с целью минимизации потерь качества выпускаемой продукции, производительности в статических режимах работы или затрат энергии в динамических является актуальной задачей. В целом, включение ИИ в автоматизацию процесса сушки приводит к повышению эффективности, экономии средств и улучшению качества продукции, что делает его ценным дополнением к отрасли [3, 4].

II. Интеллектуальная система мониторинга и управления сушкой

Для решения этой задачи предлагается использовать информационно-управляющую систему (ИУС), инвариантную различным сушильным установкам, структурная схема, которой представлена на рис. 1.

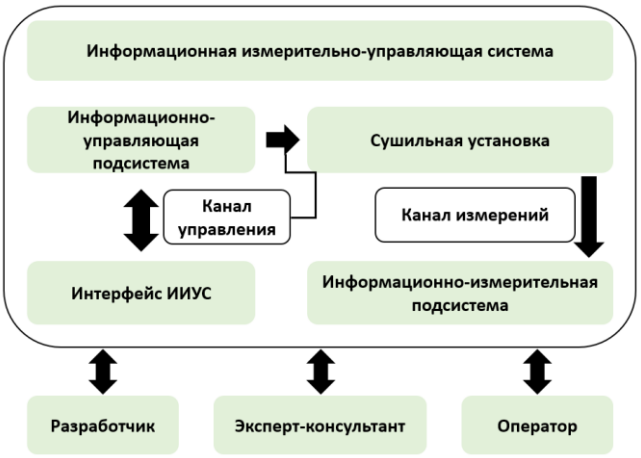

Рис. 1. Модель информационной измерительно-управляющей системы

Разработанная ИУС позволяет в реальном режиме времени вырабатывать управляющее воздействие, минимизирующее потери качества, производительности и энергетических затрат на процесс сушки. В состав ИУС входят информационно-измерительная, информационно-управляющая подсистемы и интерфейс пользователя. Интерфейс пользователя содержит интегрированную среду разработки, позволяющую перенастраивать ИУС под сушильные установки различных типов. Также неотъемлемый частью интерфейса является модуль когнитивной графики, дающий возможность визуализировать процесс принятия решений на этапе анализа управления с учетом возможных изменении ситуаций функционирования исследуемого объекта, что значительно облегчает процесс настройки системы [5]. Интерфейс информационно-измерительной подсистемы предназначен только для отображения измерительной информации.

Рис. 2. Информационно-управляющая подсистема

В основе функционирования информационно-управляющей подсистемы лежит работа следующих модулей:

- модуль идентификации ситуации, позволяющий выбрать модель и стратегию управления при изменении состояниях функционирования сушильной установки;
- модуль синтеза оптимального управления, реализующий выбранную стратегию управления;
- модуль определения меры доверия, содержащий математический аппарат, основанный на методе Демпстера–Шафера, позволяющий сделать своевременный прогноз о достижении требуемого качества выпускаемой продукции при текущей ситуации;
- модуль нечеткого логического вывода, предназначенный для вычисления значения управляющего воздействия.

Основными модулями информационно-измерительной подсистемы являются:

- модуль опроса датчиков: температуры и влажности сушильного агента снаружи и внутри сушильной установки, начальной влажности материала, наличия ворошителя, степени открытия воздухозаборного окна и шибера, времени работы вытяжного вентилятора, скорости движения ленты продуктового транспортера;
- модуль расчета влажности материала, на основании функционирований нейронных сетей.

Разаботанная ИС включает также информационно-измерительную подсистему (рис. 3).

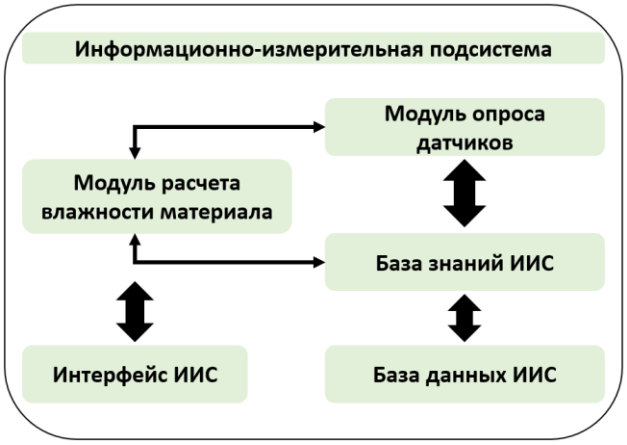

Рис. 3. Информационно-измерительная подсистема

Представленная выше информация аккумулируется в формате базы данных, в дальнейшем, преобразуемой в базу знаний. База данных (БД) информационно-управляющей подсистемы ИУС предназначена для хранения и дальнейшего использования декларативной и процедурной информации являющейся результатом работы модулей: синтеза оптимального управления, идентификации состояния функционирования, нечеткого управления, идентификации ситуации, определения меры доверия, базы знаний или результатом общения системы с внешней средой посредством интерфейса пользователя.

В статье ИУС рассматривается применительно к сушильным вальце-ленточным (СВЛ) установкам. ИУС СВЛ может обслуживать множество объектов, расположенных в различных цехах и отличающихся технологическими особенностями (например, количеством секций, типами калориферов и т. д.). Для каждого объекта в соответствии с его состоянием функционирования решаются различные задачи. В связи с этим для его описания используются различные модели. При этом в каждом конкретном случае синтезируется свой алгоритм управления. В результате для оперативного функционирования ИУС возникает необходимость хранить данные, являющиеся результатом работы ее модулей.

В качестве модели представления данных в системе была выбрана реляционная модель. Преимущество реляционной модели заключается в способе хранения данных, который минимизирует их дублирование и исключает определенные типы ошибок обработки, возникающие при других способах хранения данных. Пример фрагментов реляционной модели базы данных информационно-управляющей подсистемы приведен на рис. 4.

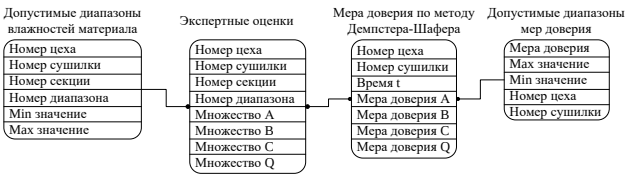

Рис. 4. Пример организации хранения данных

На практике при разработке ИУС редко удается обойтись рамками одной модели представления знаний, поэтому база знаний системы хранит фреймы знаний, представленных различными моделями знаний. При принятии решения об управлении приходится работать с неточными неопределенными знаниями и данными. Они в основном базируются на вероятностном подходе и подходе, основанном на теории нечетких множеств и нечеткой логики. В базе знаний информационно-управляющей подсистемы ИУС хранятся процедурные знания в виде фреймов позволяющие определить меру доверия полученных результатов по методу Демпстера – Шафера, а также знания, представленные в виде продукционных правил, позволяющих синтезировать управляющее воздействие в реальном режиме времени. В базе знаний информационно-измерительной подсистемы хранятся фреймы знаний, представляющие собой семейства нейронных сетей, делающих интеллектуальных датчик отказоустойчивой системой.

III. Заключение

Создание и использование баз данных и знаний, позволяющих синтезировать управляющие воздействия без участия лица, принимающего решение в реальном режиме времени с учетом смены состояний функционирования и отказов датчиков, входящих в систему, делает ИУС интеллектуальной.

В статье представлена модель интеллектуальной информационной системы управления процессами сушки. Предлагаемая модель объединяет передовые методы обработки данных, алгоритмы машинного обучения и мониторинг в реальном времени для оптимизации процесса сушки и обеспечения качества продукции. Внедрение этой интеллектуальной системы обещает повысить эффективность, снизить эксплуатационные расходы и внести вклад в устойчивое развитие сушильной отрасли. Будущие исследования должны быть сосредоточены на уточнении модели и добавлении новых функций для других промышленных процессов.

Список литературы

[1] Artemova S.V., Ladynin A.I., Shmeleva A.G. [et al.] Technological processes operational assessment frame model in automated control systems // Proceedings of 2021 IV International Conference on Control in Technical Systems (CTS), Saint Petersburg Electrotechnical University “LETI”, 21–23 сентября 2021 года. IEEE, 2021. P. 27-29. DOI 10.1109/CTS53513.2021.9562783. EDN EDHVJU.

[2] Сорокин А.Б., Железняк Л.М., Супруненко Д.В., Холмогоров В.В. Проектирование модулей системной динамики в системах поддержки принятия решений // Russian Technological Journal. 2022;10(4):18-26. https://doi.org/10.32362/2500-316X-2022-10-4-18-26

[3] Слепцов В.В., Афонин В.Л., Аблаева А.Е., Динь Б. Разработка информационно-измерительной и управляющей системы квадрокоптера. // Russian Technological Journal. 2021;9(6):26-36. https://doi.org/10.32362/2500-316X-2021-9-6-26-36

[4] Artemova S.V., Ladynin A.I., Shmeleva N.M. [et al.] Heat-technological Devices Energy-saving Management // Proceedings of 2021 IV International Conference on Control in Technical Systems (CTS), Saint Petersburg Electrotechnical University “LETI”, 21–23 сентября 2021 года. IEEE, 2021. P. 24-26. DOI 10.1109/CTS53513.2021.9562833.

[5] Sebrjakov G.G., Muzhichek S.M., Skrynnikov A.A., Pavlov V.I., Ermolin O.V. Recognition of information-measuring systems states during inaccurate measurement of its phase coordinates vector // Herald of computer and information technologies, 2016, no 11, pp. 15-19. DOI: 10.14489/vkit.2016.11. pp.015-019

Классификация и прогнозирование заболеваний легких по данным рентгенографии грудной клетки

Р. И. Думаев[1], С. А. Молодяков[2]
Санкт-Петербургский политехнический университет им. Петра Великого
Высшая школа программной инженерии
[1]dumaevrinat@gmail.com, [2]molodyakov_sa@spbstu.ru

***Аннотация*. Рентгенография грудной клетки – недорогой и эффективный и широко используемый подход, который позволяет выявить заболевания легких. В данной работе предложен метод автоматической классификации и прогнозирования легочных патологий фронтально-грудной рентгенографии. Были рассмотрены несколько архитектур и различные глубины моделей для извлечения признаков из изображения. Представленный подход основан на распознавании заболеваний по изображению грудной клетки и метаданным снимка (возраст, пол пациента, тип получения снимка). Проведено сравнение эффективности предлагаемого подхода для различных архитектур с другими методами классификации патологий с помощью статистики ROC на публичной тестовой выборке набора данных, содержащий более 112 тысяч размеченных снимков. Архитектура модели, адаптированная для работы с данными пациентов и основанная на сверточной сети ResNet-34, дает наилучшие результаты среднего показателя AUC.**

Ключевые слова: глубокое обучение, сверточная нейронная сеть, заболевание легких, рентгенография грудной клетки

I. Введение

Рентгенография органов грудной клетки (рентген грудной клетки) является неинвазивным методом исследования, позволяющим получить информацию о заболеваниях легких, не вызывая дискомфорта у пациента [1].

Для оценки состояния легких, выявления и диагностики таких заболеваний, как бронхит, инфильтрация, ателектаз, переломы, рентгенологи в основном используют рентгенографию органов грудной клетки [2]. Рентгенография грудной клетки считается наиболее часто используемым методом обследования заболеваний в мире: ежегодно выполняется более двух миллионов процедур [3]. Компьютерные системы могут использоваться для улучшения эффективности рабочего процесса и принятия клинических решений и интерпретации рентгенограмм грудной клетки [4].

Существует большое количество методов обработки рентгеновских снимков, которые применяются в распознавании заболеваний легких и извлечении признаков. В компьютерном зрении глубокое обучение уже продемонстрировало свою способность классифицировать изображения с высокой точностью. Кроме того, глубокое обучение активно исследуется в области обработки медицинских изображений, существует большое количество методов обработки рентгеновских снимков, которые применяются в распознавании заболеваний легких и извлечении признаков [5]. Автоматическая диагностика изображений грудной клетки привлекает все большее внимание для создания систем генерации медицинских отчетов [6, 7]. Алгоритмы глубокого обучения предоставляют возможность анализировать огромные объемы данных и достигать высоких значений точности.

Публикация Национального института здравоохранения общедоступного датасета ChestXray14 [8] привела к многочисленным исследованиям с использованием глубокого обучения для диагностики с помощью рентгенографии грудной клетки [9]. В работе [8] оценивалась производительность с использованием четырех стандартных архитектур сверточных нейронных сетей CNN (AlexNet, VGGNet, GoogLeNet и ResNet [10]). В работе [11] предложена комбинация CNN и RCNN (Recurrent Neural Network) для увеличения взаимозависимостей между метками при прогнозировании 14 патологических паттернов на рентгенограммах грудной клетки.

Помимо этого, часть работ демонстрирует результаты путем случайного разделения данных для обучения, валидации и тестирования, что проблематично, поскольку для ChestX-Ray14 на одного пациента приходится несколько снимков. Таким образом, снимки одного и того же пациента могут появиться как в обучающей, так и в тестовой выборке. Кроме того, несбалансированность классов в датасете также делает сравнение показателей проблематичным для случайного разбиения всего датасета. В нашей работе предложенный метод сравнивается с другими подходами на публичной тестовой выборке ChestXray14, в которой нет пересечений пациентов.

Все работы, связанные с набором данных ChestX-Ray14, ограничиваются только анализом изображений. Однако в клинической практике рентгенологи используют широкий спектр дополнительных признаков при диагностике. В данной работе представлен подход, основанный на распознавании заболеваний с помощью использования различных архитектур CNN для извлечения признаков изображения грудной клетки и метаданных снимка пациента (возраст, тип получения снимка, пол пациента). Проведены сравнения различных архитектур CNN, размерностей входного изображения и использование дополнительных данных о пациенте.

II. НАБОР ДАННЫХ

Для обучения алгоритмов глубокого обучения была использована база данных снимков NIH Chest X-ray14 [8], которая является одной из крупнейших общедоступных баз данных рентгеновских снимков, содержащих 112,120 снимков грудной клетки в передней-задней AP или задне-передней PA проекциях для 30,805 пациентов. Каждое изображение размечено 14 различными патологическими признаками. Признак каждого изображения был получен с помощью метода автоматического извлечения из рентгенологического отчета, каждое изображение содержит 14 бинарных значений для соответствующей патологии: ателектаз (atelectasis), кардиомегалия (cardiomegaly), лёгочная консолидация (consolidation), отек легких (edema), плевральный выпот (effusion), эмфизема легких (emphysema), фиброз (fibrosis), грыжа (hernia), инфильтрация (infiltration), образования в легких (mass), легочный узел (nodule), плевральное утолщение (pleural thickening), пневмония (pneumonia), пневмоторакс (pneumothorax). На рис. 1 приведены примеры снимков для некоторых патологий.

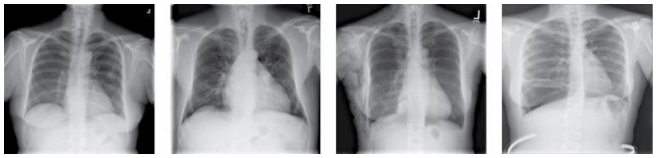

Рис. 1. Несколько примеров снимков датасета NIH Chest X-ray14 с соответсвующими порядку изображений патологическими признаками: без признаков, кардиомегалия и два снимка с пневмотораксом.

Кроме того, размер каждого изображения равен 1024×1024 пикселей. В табл. 1 показано распределение каждого класса патологии и статистика метаинформации о снимке пациента. Распространенность отдельных патологий в целом невелика и колеблется от 0.2 % до 17.74 % от всего количества снимков, при этом распределение пациентов по полу и типу снимка достаточно равномерное с соотношением 1.3 и 1.5 соответственно (табл. 1). Средний возраст пациентов составляет 46.9 лет со стандартным отклонением 16.6 лет.

ТАБЛИЦА I. ОБЗОР МЕТАИНФОРМАЦИИ В НАБОРЕ ДАННЫХ

Пол пациента	Женский	Мужской	Соотношение
	63,340	48,780	1.3
Проекция снимка	PA	AP	Соотношение
	67,310	44,810	1.5

Набор данных содержит несбалансированный набор снимков для всех патологий. Так, например, количество изображений, которые содержат отек легкого, намного меньше, чем количество изображений без данного признака: 2303 и 109,817 соответственно. Чтобы решить проблему несбалансированности классов, для обучения была использована binary focal cross-entropy функция потерь.

III. МЕТОДОЛОГИЯ

Далее мы рассматриваем обнаружение патологии как проблему multi-label классификации с несколькими метками. Для извлечения признаков из изображения используется архитектура ResNet-34, данная архитектура показала наилучшие результаты по сравнению с другими архитектурами. Помимо изображения на вход модели также подается вектор признаков, содержащий метаинформацию о снимке. Последний dense слой модели с функцией активации sigmoid соответствует количеству меток. Метки состоят из вектора размерностью n [l_1, l_2, ..., ln], где n=14 и двоичными значениями, где значение 0 соответствует отсутствию признака, а значение 1 наличию патологии. В multi-label классификации обрабатываем все метки во время классификации независимо, определяя focal binary cross-entropy в качестве функции потерь. Эта функция потерь хорошо работает с сильно несбалансированными наборами данных. Данная функция потерь фокусирует обучение на небольшом наборе сложных положительных примеров с патологией и предотвращает переобучение классификатора во время обучения огромным количеством негативных снимков без найденных патологий.

A. *Transfer learning*

Возможны две основные стратегии инициализации параметров модели:

- Схема, в которой параметры сети инициализируются случайными значениями, и таким образом модель обучается с нуля.
- Инициализация сети с предварительно обученными весами, в которой перенесены знания сети из другой области и задачи (transfer learning).

Основным недостатком при обработке медицинских изображений с помощью глубокого обучения является ограниченный размер наборов данных по сравнению с областью компьютерного зрения. Следовательно, обучение CNN с нуля часто невозможно. В данной работе была использована предварительно обученная CNN для извлечения признаков снимка на датасете ImageNet, при этом были дообучены все слои сети (fine-tuning).

B. *Архитектура модели*

Набор данных ChestX-ray14 содержит информацию о возрасте, поле и положении пациента (передней-задняя AP или задне-передняя PA проекции). Рентгенологи используют информацию, не относящуюся к изображению, чтобы сделать вывод о том, какие патологии присутствуют, а какие нет. Также тип проекции изменяет ожидаемое положение органов на рентгеновских изображениях.

Была реализована модель, архитектура которой представлена на рис. 2, помимо изображения, модель принимает на вход вектор признаков размерностью 3, содержащий данные о возрасте, пол пациента, тип снимка. Как показано на рис. 2, мы объединяем вектор признаков изображения (то есть выходные данные последнего Global Max Pooling слоя с размерностью 512×1) с новым вектором полносвязанного слоя на основе признаков метаданных размерностью 8×1.

Для извлечения признаков из изображения была использована глубокая сверточная сеть ResNet-34.

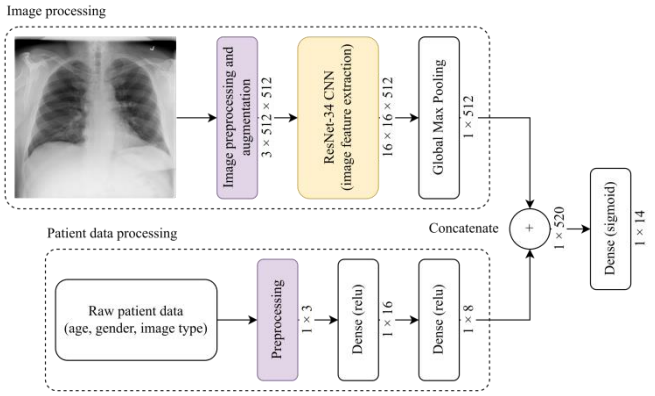

Рис. 2. Архитектура модели, адаптированная для работы с данными пациентов, основана на сверточной сети ResNet-34

C. Обработка данных и обучение

Для повышения вычислительной эффективности размерность входных данных 1024×1024 уменьшается до 512×512. Такая размерность является оптимальной, в работе [12] были проведены сравнения нескольких размеров и пришли к выводу, что для более мелких патологий, таких как легочные узлы и новообразования, наблюдается уменьшение метрики AUC на 0,018 и 0,006 соответственно на снимках меньшей размерности. Тип снимка и пол пациента кодируются как {0,1}, а возраст линейно масштабируется в диапазоне [0, 1].

Тренировочная выборка состоит из 85,009 снимков, тестовая выборка содержит 25,292 снимка. Были применены несколько операций аугментации для предотвращения переобучения: случайное отражение снимка по горизонтали, случайный поворот снимка, случайное увеличение и обрезание снимка, изменения контрастности и яркости изображения, добавление шума на изображение [13].

В качестве оптимизатора был использован Adam [14] с параметрами по умолчанию, скорость обучения lr = 0.001, batch size = 128 (16 на каждое TPU ядро). Во время обучения скорость обучения уменьшается в 2 раза, если значение функции потерь при проверке не уменьшается в течение 2 эпох на валидационной выборке.

Для обучения моделей был использован тензорный процессор от Google (TPU) на платформе Kaggle. TPU позволяет обучать более крупные модели, а также использовать более крупные обучающие входные данные. В ходе работы весь исходный датасет был обработан и преобразован в датасет, содержащий все данные исходного датасета, с меньшим количеством файлов формата TFRecords для оптимального обучения на TPU (все снимки и метаинформация исходного датасета были сгруппированы в 432 файла, каждый размером ≈ 100 MB), уменьшив ожидание на доступ к каждому отдельному файлу и сократив время обучения для одной эпохи с 36 минут до 4.3 минут (время, затраченное на обучении модели, основанной на архитектуре ResNet-34).

Так как TPU считывают тренировочные данные исключительно из GCS (Google Cloud Storage), то полученный датасет был загружен на платформу Kaggle, что позволило достичь довольно большой пропускной способности при обучении и тестировании модели.

IV. Эксперименты и результаты

Проведено несколько экспериментов для сравнения различных архитектур извлечения признаков снимка, используя публичную тестовую выборку Chest-Xray14, в которой нет пересечений пациентов, и ROC-анализ, используя площадь под кривой (AUC) для всех патологий. Сравнены основные архитектуры глубоких CNN в качестве моделей извлечения признаков изображения, результаты представлены в табл. 2.

Помимо различных архитектур для извлечения признаков были обучены и сравнены модели с разным количеством слоев архитектуры ResNet (ResNet-34 и ResNet-50), результаты сравнения также представлены в табл. 2. Данная архитектура с различным количеством слоев часто используется и в других исследованиях [15, 16].

ТАБЛИЦА II. Сравнение CNN архитектур для извлечения признаков изображения

Патология	**Dense Net121**	**Efficient NetB3**	**ResNet 34**	**ResNet 50**
Infiltration	0.708	0.688	0.739	0.698
Effusion	0.818	0.682	0.822	0.808
Atelectasis	0.770	0.657	0.788	0.732
Nodule	0.782	0.787	0.779	0.713
Mass	0.814	0.671	0.847	0.690
Pneumothorax	0.844	0.787	0.868	0.840
Consolidation	0.714	0.673	0.751	0.704
Pleural Thickening	0.757	0.731	0.789	0.695
Cardiomegaly	0.832	0.606	0.889	0.768
Emphysema	0.913	0.704	0.929	0.842
Edema	0.819	0.803	0.901	0.806
Fibrosis	0.722	0.797	0.837	0.721
Pneumonia	0.723	0.714	0.738	0.686
Hernia	0.883	0.826	0.908	0.811
Среднее	0.793	0.723	0.828	0.751

Архитектура ResNet показала наибольшее среднее значение метрики AUC и наибольшее значение для 13 из 14 патологий. Уменьшение количества слоев ResNet позволило увеличить значение AUC с 0.751 до 0.828. Результаты показывают, что обучение модели с меньшим количеством параметров на наборе данных Chest-Xray14 положительно влияют на общую производительность подхода.

V. Сравнение с другими подходами

В табл. 3 представлено сравнение значений AUC ROC для каждой патологии на официальной тестовой выборке для основных работ. Кроме того, приведено среднее значение AUC по всем патологиям, жирным шрифтом выделено максимальное значение AUC для данной патологии.

Предложенный метод был сравнен с другими основными работами на официальном публичном тестовом наборе базы данных Chest-Xray14. Для сравнения была выбрана модель на основе ResNet с количеством слоев равным 34 и входным размером изображения, равным 512×512 пикселей, имевшая наибольшее значение AUC ROC в ходе проведения экспериментов с различными архитектурами CNN в качестве модели извлечения признаков снимка пациента и разной размерностью входного изображения.

ТАБЛИЦА III. СРАВНЕНИЕ РЕЗУЛЬТАТОВ НА ОФИЦИАЛЬНОЙ ТЕСТОВОЙ ВЫБОРКЕ

Патология	**[8]**	**[11]**	**[17]**	**[12]**	**Наш метод**
Infiltration	0.661	0.673	0.711	0.709	**0.739**
Effusion	0.759	0.806	**0.876**	0.828	0.822
Atelectasis	0.700	0.733	**0.794**	0.755	0.788
Nodule	0.669	0.724	0.743	0.758	**0.779**
Mass	0.693	0.777	0.826	0.821	**0.847**
Pneumothorax	0.799	0.805	**0.880**	0.846	0.868
Consolidation	0.703	0.711	**0.790**	0.749	0.751
Pleural Thickening	0.684	0.724	0.763	0.761	**0.789**
Cardiomegaly	0.810	0.856	0.885	0.875	**0.889**
Emphysema	0.833	0.842	0.891	0.895	**0.929**
Edema	0.805	0.806	0.884	0.846	**0.901**
Fibrosis	0.786	0.743	0.762	0.818	**0.837**
Pneumonia	0.723	0.684	0.733	0.731	**0.738**
Hernia	0.896	0.775	0.811	**0.937**	0.908
Среднее	0.745	0.761	0.810	0.806	**0.828**

Метод с использованием метаданных пациента имеет в 9 из 14 патологий значение метрики AUC выше по сравнению с работами [12, 17], а также наибольшее среднее значение.

VI. ЗАКЛЮЧЕНИЕ

Был представлен подход, основанный на глубокой CNN для извлечения признаков изображения грудной клетки и метаданных снимка пациента (возраст, тип получения снимка, пол пациента) для классификации патологий на рентгеновских изображениях грудной клетки. Проведены сравнения различных архитектур CNN, размерностей входного изображения и использование дополнительных данных о пациенте. Был создан датасет, содержащий все данные исходного датасета, но с меньшим количеством файлов формата TFRecords для оптимального обучения на TPU, сократив время обучения для одной эпохи с 36 минут до 3.8 минут (время при обучении модели, основанной на архитектуре ResNet-34). Модель на основе ResNet с меньшим количеством параметров на наборе данных Chest-Xray14 имеет лучшую производительность.

Разработанный подход, основанный на ResNet-34 и дополнительных данных пациентов, имеет в 9 из 14 патологий значение метрики AUC выше по сравнению с работами [12, 17] (имели лучшие результаты по всем четырнадцати классам) на официальном тестовом наборе данных, модель достигла среднего значения AUC ROC равным 0.828.

Полученные результаты свидетельствуют о том, что глубокое обучение в области медицины является перспективным, так как доступны все больше и больше общедоступных данных. Однако практическое применение глубокого обучения в клинической практике остается открытой темой, особенно для набора данных ChestX-ray14 с довольно высоким уровнем шума разметки.

СПИСОК ЛИТЕРАТУРЫ

[1] Gazda M., Plavka J., Gazda J., Drotar P. Self-Supervised Deep Convolutional Neural Network for Chest X-Ray Classification // IEEE Access. 2021. V. 9. P. 151972–151982. DOI: 10.1109/access.2021.3125324.

[2] Kido S., Hirano Y., Hashimoto N. Detection and classification of lung abnormalities by use of convolutional neural network (CNN) and regions with CNN features (R-CNN) // International Workshop on Advanced Image Technology (IWAIT). 2018. DOI: 10.1109/IWAIT.2018.8369798.

[3] Kaviani P., Digumarthy S. R., Bizzo B. C., Reddy B., Tadepalli M., Putha P., Jagirdar A., Ebrahimian S., Kalra M. K., Dreyer K. J. Performance of a Chest Radiography AI Algorithm for Detection of Missed or Mislabeled Findings: A Multicenter Study // Diagnostics. 2022. V. 12. №9. P. 2086. DOI: 10.3390/diagnostics12092086.

[4] Davenport T., Kalakota R. The potential for artificial intelligence in healthcare // Future Healthcare Journal. 2019. V. 6. №2. P. 94–98. DOI: 10.7861/futurehosp.6-2-94.

[5] Ayan E., Karabulut B., Ünver H. M. Diagnosis of Pediatric Pneumonia with Ensemble of Deep Convolutional Neural Networks in Chest X-Ray Images // Arabian Journal for Science and Engineering. 2021. V. 47. №2. P. 2123–2139. DOI: 10.1007/s13369-021-06127-z.

[6] Qin C., Yao D., Shi Y., Song Z. Computer-aided detection in chest radiography based on artificial intelligence: A survey // BioMedical Engineering OnLine. 2018. V. 17. №1. DOI: 10.1186/s12938-018-0544-y.

[7] Cicero M., Bilbily A., Colak E., Dowdell T., Gray B., Perampaladas K., Barfett J. Training and Validating a Deep Convolutional Neural Network for Computer-Aided Detection and Classification of Abnormalities on Frontal Chest Radiographs // Investigative Radiology. 2017. V. 52. №5. P. 281–287.

[8] Wang X., Peng Y., Lu L., Lu Z., Bagheri M., Summers R. M. ChestX-Ray8: Hospital-Scale Chest X-Ray Database and Benchmarks on Weakly-Supervised Classification and Localization of Common Thorax Diseases // IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Jul. 2017. DOI: 10.1109/cvpr.2017.369.

[9] Çallı E., Sogancioglu E., Ginneken B., Leeuwen K. G., Murphy K. Deep learning for chest X-ray analysis: A survey // Medical Image Analysis 2021. V. 72. P. 102125. DOI: 10.1016/j.media.2021.102125.

[10] He K., Zhang X., Ren S., Sun J. Deep Residual Learning for Image Recognition // IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Jun. 2016, DOI: 10.1109/cvpr.2016.90.

[11] Yao L., Poblenz E., Dagunts D., Covington B., Bernard D., Lyman K. Learning to diagnose from scratch by exploiting dependencies among labels // arXiv preprint arXiv:1710.10501, 2017.

[12] Baltruschat I. M., Nickisch H., Grass M., Knopp T., Saalbach A. Comparison of Deep Learning Approaches for Multi-Label Chest X-Ray Classification // Scientific Reports. 2019. V. 9. №1. DOI: 10.1038/s41598-019-42294-8.

[13] Думаев Р.И., Киряков И.М., Молодяков С.А. Особенности предобработки и сегментации изображений в задаче обнаружения COVID-19 по рентгеновским снимкам // Современная наука: актуальные проблемы теории и практики. Серия: Естественные и Технические Науки. 2022. №9. С. 88-95. DOI: 10.37882/2223–2966.2022.09.08

[14] Kingma D.P., Ba J. Adam: A method for stochastic optimization // arXiv preprint arXiv:1412.6980, 2014.

[15] Owais M., Arsalan M., Mahmood T., Kim Y. H., Park K. R. Comprehensive Computer-Aided Decision Support Framework to Diagnose Tuberculosis From Chest X-Ray Images: Data Mining Study // JMIR Medical Informatics. 2020. V. 8. №12. P. e21790. DOI: 10.2196/21790.

[16] Kusakunniran W., Borwarnginn P., Sutassananon P., Tongdee T., Saiviroonporn P., Karnjanapreechakorn S., Siriapisith T. COVID-19 detection and heatmap generation in chest x-ray images // Journal of Medical Imaging. 2021. V. 8. №S1. DOI: 10.1117/1.jmi.8.s1.014001.

[17] Souid A., Sakli N., Sakli H. Classification and Predictions of Lung Diseases from Chest X-rays Using MobileNet V2 // Applied Sciences. 2021. V. 11. №6. P. 2751.

Подход к определению динамики запаса газа на основе нейронных дифференциальных уравнений

А. К. Петрова
Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» им. В.И. Ульянова (Ленина)
akpetrova@etu.ru

***Аннотация*. Динамика системы управления запасом газа в системе магистральных газопроводов определяется изменениями расхода, давления, температуры газа и факторов небаланса. Поскольку численно решить уравнения динамики запаса затруднительно, в настоящее время исследуется применение для решения таких задач алгоритмов машинного обучения. В данной статье рассматривается использование для решения задач динамики запаса газа обыкновенного дифференциального уравнения ОДУ (ODE, ordinary differential equation).**

Ключевые слова: газотранспортная система, баланс, запас газа, алгоритмы машинного обучения, динамический режим, нейронные обыкновенные дифференциальные уравнения

I. Введение

Сеть магистрального газопровода представляет собой совокупность соединенных между собой компрессорных станций, пунктов редуцирования давления и линейных устройств. Движение газа по магистральному газопроводу считается стационарным и неизотермическим, а промежуточные притоки и отборы газа – фиксированными. Исходными данными являются параметры линейных устройств, состав и характеристики оборудования компрессорных станций, химический состав газа и температура окружающей среды [1–3].

Кроме этого на всех входах и выходах сети задаются граничные условия, которыми являются зависимости давления от расходов (P(Q)), минимально и максимально допустимый расход, минимально и максимально допустимое давление, температура газа (только для входов), а на компрессорных станциях – ограничения по давлению нагнетания и степени сжатия. В качестве граничного условия можно также задать максимально допустимую сумму поступлений газа или величину запаса, находящегося в магистральном газопроводе.

Математическая модель, описывающая стационарное движение газа по МГ и учитывающая технологические ограничения описывается при помощи уравнения движения газа

$$(P^2_н + \Delta P^2_н) - (P^2_к - \Delta P^2_к) = \lambda Q \quad (1)$$

где Q – расход на участке; $P^2_н$ – квадрат давления в начале участка; $P^2_к$ – квадрат давления в конце участка; $\Delta P^2_н$, $\Delta P^2_к$ – перепад квадратов давлений на компрессной станции, соответственно в начале и в конце участка, λ – коэффициент, учитывающий геометрические и иные характеристики.

Можно сказать, что для эффективной работы системы транспорта газа необходимо решить задачу оптимизации. Целью решения задачи оптимизации управления балансом газа является определение с учетом технологических ограничений режима работы сети магистрального газопровода, обеспечивающего максимальное значение критерия оптимизации и удовлетворяющего заданным граничным условиям на входах и выходах сети.

Критерием оптимизации может быть:

- минимум расхода газа на собственные нужды;
- максимум производительности (сумма расходов газа на входах);
- максимум прибыли (стоимость проданного газа - стоимость купленного газа – стоимость расхода газа на собственные нужды);
- минимум расхода на компенсацию расчетно-методической погрешности запаса газа в магистральном газопроводе.

Рассмотрим далее последнюю составляющую, запас газа в магистральном газопроводе.

II. Запас газа в системе управления балансом газа

Запас газа является одним из элементов системы управления балансом газа в магистральном газопроводе. Величина запаса газа нелинейно зависит от совокупности таких физических величин, как давление, температура, плотность и состав газа, а также характеристик трубопровода [4–6]:

$$Q_{запас} = F\,(P, T, Z, \rho_{ст}, \mu_{ху}, \mu_{ха}, L, D_{вн}) \quad (2)$$

В данном выражении:

P – давление в трубопроводе, кгс/см^2; T – температура на трубопроводе, °С; Z – коэффициент сжимаемости; $\rho_{ст}$ – плотность природного газа, транспортируемого по МГ, ρ, кг/м^3, при стандартных условиях ($P_с$ = 0,1013 МПа и $T_с$ = 293,15 K); $\mu_{ха}$ = 28.0135; молярная доля азота кг/моль, определяемая по ГОСТ 30319.1; $\mu_{ху}$ = 44.010; % молярная доля диоксида углерода кг/моль, определяемая по ГОСТ 30319.1; L, $D_{вн}$ – соответственно длина и внутренний диаметр нитки магистрального газопровода.

При этом методика расчета запаса газа газотранспортных предприятий 15.09.1999. признана

устаревшей, аналог расчетов приведен в СТО Газпром 2-3.5-051–2006.

Согласно этому документу, для расчета средней температуры в нитке магистрального газопровода T используются величины $K_{ср}$ – средний на участке общий коэффициент теплопередачи от газа в окружающую среду, Вт/м^2·К и $C_{ср}$ – средняя изобарная теплоемкость газа, кДж/кг·К.

В свою очередь, для расчёта $C_{ср}$ и $K_{ср}$, в формулах присутствуют приведенное давление и приведенная температура;

$P_{пр}$ – приведенное давление:

$$P_{пр} = \frac{P}{P_{пк}} \quad (3)$$

$T_{пр}$ – приведенная температура:

$$T_{пр} = \frac{T}{T_{пк}} \quad (4)$$

$T_{пк}$, $P_{пк}$ – псевдокритические значения давления и температуры i-го компонента газовой смеси, определяемые по [12].

$P_{пк} = 2.9585\ (1.608 - 0.05994\rho_{ст} + \mu_{ху} - 0.392\mu_{ха})$

$T_{пк} = 88.25\ (0.9915 + 1.759\ \rho_{ст} - \mu_{ху} - 1.681\mu_{ха})$

Согласно формуле (4), для расчета $T_{пр}$ необходимо снова использовать температуру в нитке магистрального газопровода T, то есть расчет температуры зацикливается, а, следовательно, расчет запаса газа нереализуем.

Согласно опроса экспертов, в настоящее время на газотранспортных предприятиях используются приблизительные методы расчета запаса газа в магистральном газопроводе, что может оказывать влияние на точность, а, следовательно, на эффективность управления балансом газотранспортной системы, сказываться на ее экономических показателях. По этой причине является важной разработка актуальных методик расчёта запаса газа и его динамики в магистральном газопроводе.

III. Моделирование режимов управления балансом газа

Моделирование стационарных режимов управления балансом газа осуществляется на основе предположения о его прямой зависимости небаланса от объемов влияния факторов-причин его возникновения σ и обратной зависимости от объемов, направленных на его устранение, в частности, при помощи компенсацию расчетно-методической погрешности запаса газа в магистральном газопроводе. $Q_{зап\ комп}$:

$$Q_{зап} = F\frac{\sigma}{Q_{зап\ комп}} = F\frac{\sigma}{Q_{корр}} \quad (5)$$

Динамика системы управления балансом газа определяется изменениями расхода на поддержание баланса, в том числе, компенсацию расчетно-методической погрешности запаса газа, и влиянием факторов – причин небаланса, следствием влияния которых является, в частности, изменение температуры газа в сети и необходимость его корректировать [7]:

$$A\frac{dT_{корр}}{dt} = Q_{зап} - Q_{зап\ комп} \quad (6)$$

$$B\frac{dQ_{зап\ комп}}{dt} = T_{зад} - T_{корр} \quad (7)$$

где A и B – коэффициенты пропорциональности.

Численно решить данные уравнения не представляется возможным, ввиду неопределённости большого числа нелинейно меняющихся факторов. Для решения таких задач в настоящее время исследуется применение алгоритмов машинного обучения, и в частности, нейронных сетей с использованием обыкновенного дифференциального уравнения ОДУ (ODE, ordinary differential equation) [8, 9].

Нейронное ОДУ является операцией глубокого обучения, которая возвращает решение ОДУ. В частности, на основе входных данных, нейронная операция ODE выводит числовое решение ОДУ, $y' = f(t, y, \theta)$, в течение периода времени (t_0, t_1) и начальное условие $y(t_0) = y_0$, где t,y – входные параметры функции ОДУ, а θ – набор настраиваемых параметров.

IV. Решение уравнения запаса газа при помощи нейронного ОДУ

Уравнение для расчета запаса газа может быть представлено в виде:

$$Q_{зап} = V\frac{P\,T_c}{Z\,T\,P_c} \quad (8)$$

На данном этапе рассматривалась динамика одного из факторов уравнения (1), температуры газа в нитке магистрального газопровода, остальные для простоты расчетов были зафиксированы. В дальнейшем необходимо рассмотрение влияния динамики всех факторов, на основе решения задач частного дифференцирования.

Тогда, уравнение динамики запаса газа в зависимости от изменения температуры T в газопроводе можно представить в виде:

$$\frac{dQ_{зап}}{dt} = C \cdot \frac{dQ_{зап}}{dT} / \frac{dT}{dt} \quad (9)$$

Можно записать уравнение 8 в следующем виде:

$$Q_{зап}' = \frac{C \cdot Q_{зап}}{T} \quad (10)$$

Это ОДУ имеет аналитическое решение:

$$Q_{зап}' = C \cdot T + C_1 \quad (11)$$

где C и C_1 – коэффициенты.

Задача: найти коэффициенты C и C_1, для построения зависимости динамики запаса газа от изменения рассматриваемого входного фактора.

Таким образом, на вход нейросети, для решения дифференциального уравнения динамики запаса газа в зависимости от динамики температуры в нитке газопровода, подавалась тренировочная выборка значений, полученная в результате измерений на одном из участков Калининградского участка Северо-Западной газотранспортной сети. График изменения входного параметра во времени представлен на рис. 1.

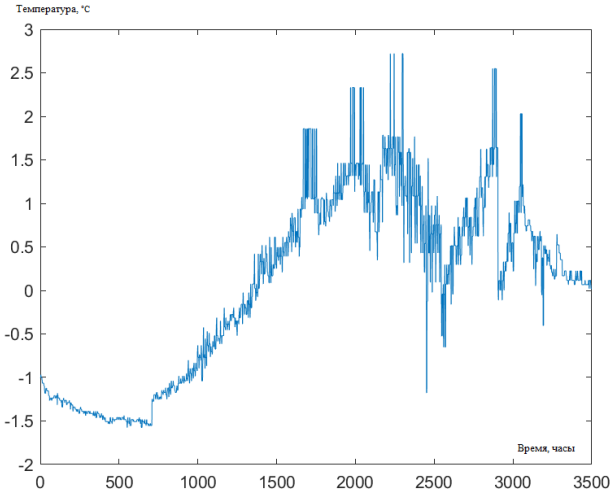

Рис. 1. График входного параметра, температуры в нитке магистрального газопровода

Сеть обучалась с помощью цикла в среде Matlab [10]. В течение каждой эпохи данные группировались по мини-пакетам. Для каждого мини-пакета оценивались градиенты модели и потерь с помощью функций *dlfeval* и *modelGradients*. Сетевые параметры обновлялись при помощи функции *sgdmupdate*. На рис. 2 показан прогресс обучения.

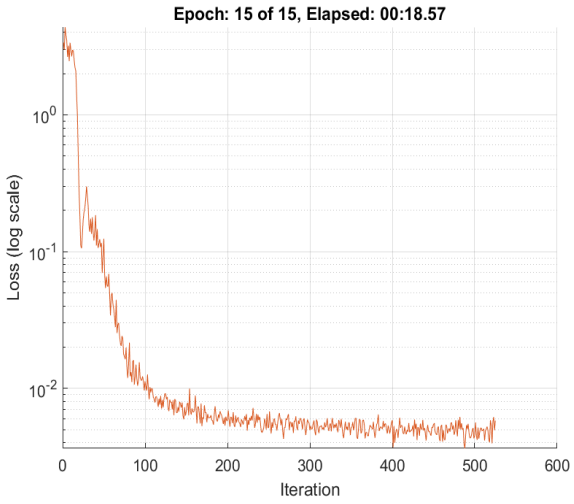

Рис. 2. Прогресс обучения

Сравнивались аналитическое решение и решение нейросети. Графики этих решений проиллюстрированы на рис. 3.

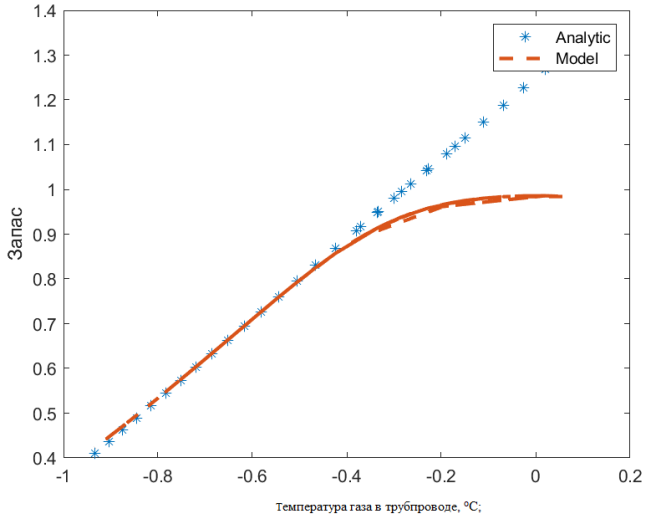

Рис. 3. Сравнение предсказания модели с аналитическим решением

Путем экспериментов удалось подобрать коэффициенты C и C_1, формулы (11), для температуры на входе нитки газопровода, чтобы получить максимальное приближение к значениям запаса, полученным аналитически. Результаты представлены в табл. 1.

ТАБЛИЦА I. СРАВНЕНИЕ РЕЗУЛЬТАТОВ НЕЙРОСЕТЕВОЙ МОДЕЛИ И АНАЛИТИЧЕСКОГО РЕШЕНИЯ

C	C_1	Ошибка RMSE
1.5	3	0.1158
0.9	1.25	0.016

Далее аналитическое решение дифференциального уравнения и решение нейросети были применены к тестовой выборке значений входного параметра – температуры, и получившиеся значения $Запас_{аналит}$ и $Запас_{мод}$ сравнивались с тестовой выборкой значений запаса газа $Запас_{тест}$, рассчитанными по результатам измерений на основе принятых регламентов методик.

Также была посчитана среднеквадратическая ошибка RMSE (Root Mean Square Error), показывающая разницу:

- между значениями тестовой выборки $Запас_{тест}$ и значениями запаса, полученными аналитически $Запас_{аналит}$;
- между значениями тестовой выборки $Запас_{тест}$ и значениями запаса, полученными при помощи дифференцирования нейронной сетью $Запас_{мод}$;
- между значениями, полученными аналитически и значениями $Запас_{аналит}$, полученными при помощи дифференцирования нейронной сетью $Запас_{мод}$.

Результаты сравнения и вычислений ошибки представлены на рис. 4.

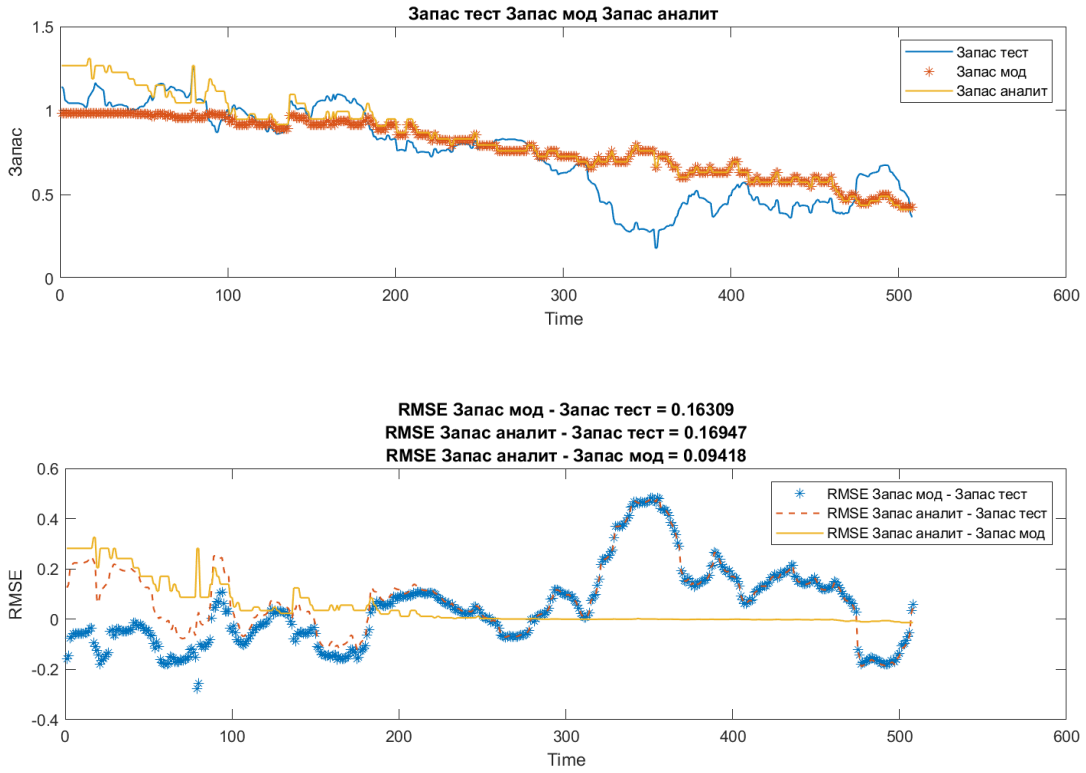

Рис. 4. Сравнение предсказания модели, аналитического решения и значени тестовой выборки (верхний график) и среднеквадратическая ошибка RMSE (нижний график)

На данном рисунке можно увидеть, что изменение входного параметра – температуры – оказывает влияние на изменение результирующего параметра – запаса газа в магистральном газопроводе, и влияние это обратное, что соответствует формуле (10).

При этом разница между значениями тестовой выборки и значениями запаса, полученными аналитически, а также между значениями тестовой выборки и значениями запаса, полученными при помощи дифференцирования нейронной сетью, довольно большая, так как на данном этапе не приняты в расчет другие множители формулы (8), а именно давление и коэффициент сжимаемости.

V. Заключение и дальнейшие перспективы исследования

В статье рассмотрен подход к определению динамики запаса газа на основе нейронных дифференциальных уравнений. Результаты показали достаточную точность предсказаний, с учетом принятых ограничений – на данном этапе рассматривалось влияние динамики одного из входных факторов, температуры газа магистральном газопроводе, остальные были зафиксированы. Поскольку расчет запаса газа влияет на баланс, а значит, на эффективность управления газотранспортной системой, представляется актуальным дальнейшие исследования в этом направлении.

В дальнейшем предполагается рассмотрение влияния на динамику запаса газа в магистральном газопроводе динамики всех входных факторов, включая давление и коэффициент сжимаемости, на основе решения дифференциальных уравнений в частных производных.

Список литературы

[1] Волков М.М., Михеев А.Л., Конев К.А. В 67 Справочник работника газовой промышленности 2-е изд., перераб. и доп. М.: Недра, 1989. 286 с.: ил. ISBN 5-247-00735-2

[2] Слободчиков К.Ю. Метод формирования расчетных примеров для диспетчерских задач транспорта газа // Газовая Промышленность 2018;3:78-86

[3] Хворов Г.А., Козлов С.И., Акопова Г.С., Евстифеев А.А. Сокращение потерь природного газа при транспортировке по магистральным газопроводам ОАО «Газпром» // Газовая промышленность. 2013. № 12. С. 66–69.

[4] Горбунов С.С., Константдян А.В., Дубинин В.А., Константдян В.А. Построение системы идентификации источников и причин небаланса газа в газотранспортной системе // Газовая Промышленность 2019;2:68-76

[5] Крымский В.Г., Жалбеков И.М., Имильбаев Р.Р., Юнусов А.Р. Автоматизация управления технологическими процессами в газораспределительных сетях: проблемы, тенденции и перспективы // Электротехнические и информационные комплексы и системы. 2013;9(2):70-79

[6] Бренц А.Д. Организация, планирование и управление на предприятиях транспорта и хранения нефти и газа : учебник для вузов / [и др.] М.: Недра, 1980.

[7] Петрова А.К. Моделирование системы контроля баланса газа в газотранспортной системе как объекта управления. // Известия СПБГЭТУ «ЛЭТИ», 2022, N10, с. 25-34.

[8] Чен, Рики Т.К., Юлия Рубанова, Джесси Бетанкур и Давид Дювено. “Нейронные Обыкновенные дифференциальные уравнения”. Предварительно распечатайте, представленный 19 июня 2018. https://arxiv.org/abs/1806.07366.

[9] Дюпон, Emilien, Арно Дусэ и Ии Вай Тех. «Увеличенные Нейронные ОДУ». Предварительно распечатайте, представленный 26 октября 2019. https://arxiv.org/abs/1904.01681.

[10] Дьяконов В.П., Круглов В.В. MATLAB 6.5 SP1/7/7 SP1/7 SP2 + Simulink 5/6. Инструменты искусственного интеллекта и биоинформации. – М.: СОЛОН-ПРЕСС, 2006.

Численное моделирование переходных процессов, используемых в магнонных резервуарных вычислениях

Андрей А. Никитин[1], Алексей А. Никитин[1], М. П. Костылев[1,2], А. Б. Устинов[1]
[1]*Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» им. В.И. Ульянова (Ленина)*
[2]*Университет Западной Австралии, Перт, Австралия*
aanikitin@etu.ru

***Аннотация*. В работе представлена численная модель для расчета переходных процессов в резервуарной вычислительной системе, построенной на спин-волновом активном кольцевом осцилляторе, в котором ввод данных осуществляется путем изменения коэффициента усиления цепи обратной связи. В основе модели лежит уравнение Гинзбурга–Ландау, описывающее нелинейный набег фазы и нелинейное затухание рабочих спиновых волн. Показано существование двух стабильных уровней выходной мощности, переходный процесс между которыми возникает в результате изменения коэффициента усиления. Теория адекватно описывает временные зависимости выходной мощности в режиме автогенерации монохроматического сигнала при условии, что временной масштаб исследуемого процесса больше периода циркуляции сигнала в кольце. В результате сравнения экспериментальных и теоретических зависимостей получено хорошее совпадение, что подтверждает применимость разработанной модели для оптимизации резервуарной системы с целью повышения ее производительности.**

Ключевые слова: искусственные нейронные сети, резервуарные вычисления, магнонный осциллятор

I. Введение

Искусственная нейронная сеть (ИНС) представляет собой вычислительную среду, которая имитирует процессы, происходящие в биологических нейронных сетях. Такая система представляет собой распределённую сеть искусственных нейронов, соединенных между собой синапсоподобными элементами, определяющими вес (силу) связи. ИНС могут выполнять различные функции обработки информации, классификации и распознавания. Физические резервуарные вычислители представляют собой особый тип ИНС, основанный на распределенной рекуррентной сети [1]. В системах с линией задержки в цепи обратной связи и временным мультиплексированием резервуар является скрытым внутренним слоем системы, состоящим из N виртуальных узлов, равномерно распределенных на времени задержки, обеспечивающих преобразование сигнала между входным и выходным слоями (рис. 1*а*) [2].

Отличительная особенность резервуарных вычислений состоит в том, что входные веса и внутренние веса не обучаются. Задача обучения состоит в определении выходных весов, для чего может использоваться простой алгоритм обучения, например, линейная регрессия. Это позволяет значительно сократить время обучения [3]. Недавно, было показано, что перспективным способом реализации физического резервуара является использование магнонных активных кольцевых осцилляторов (МАКО) [4–6]. Такие системы обладают перспективными характеристиками для реализации физических резервуарных вычислителей, среди которых необходимо отметить производительность, скорость обучения, память, энергоэффективность и масштабируемость [7].

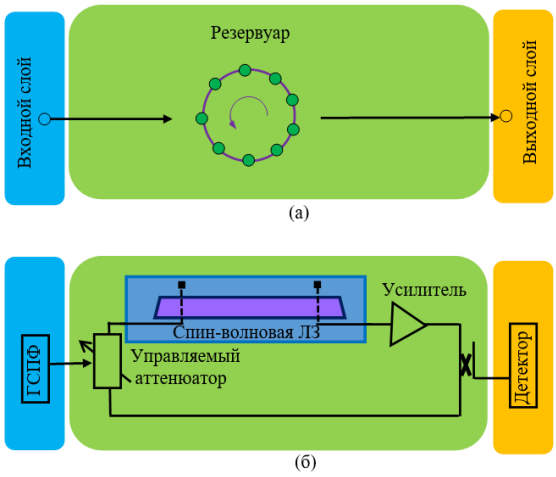

Рис. 1. Схема резервуарного вычислителя (а); схема магнонного активного кольцевого осциллятора (б)

МАКО состоит из СВЧ направленного ответвителя, электронного регулируемого аттенюатора, усилителя и спин-волновой линии задержки (рис. 1*б*). Направленный ответвитель используется для выведения небольшой части генерируемого сигнала из кольца. Генератор сигналов произвольной формы (ГСПФ) и электронный управляемый аттенюатор регулируют усиление в кольце. Усилитель обеспечивает положительную обратную связь, поддерживая режим автогенерации сигнала. Ключевым компонентом МАКО является нелинейная спин-волновая (магнонная) линия задержки. Изменение коэффициента усиления кольца приводит к возникновению медленного нелинейного переходного процесса на новую установившуюся амплитуду автоколебаний. Такой переходный процесс лежит в основе работы МАКО в качестве физического резервуара.

Работа в СПбГЭТУ «ЛЭТИ» выполнена при поддержке Министерства науки и высшего образования Российской Федерации в рамках «Мегагранта» (соглашение № 075-15-2021-609).

В данной работе представлена оригинальная теоретическая модель, описывающая нелинейные переходные процессы в МАКО с переменным коэффициентом усиления.

II. Теоретическая модель переходных процессов в магнонных активных кольцевых осцилляторах

В основе переходных процессов в исследуемых системах лежат два нелинейных четырехволновых явления, а именно: нелинейное затухание и нелинейный набег фазы [8–15]. В соответствии с этими работами два следующих дифференциальных уравнения описывают нелинейную эволюцию амплитуды и фазы спиновой волны:

$$\frac{\partial u}{\partial z}+\frac{\upsilon_1}{V_g}u^3+\frac{\upsilon_2}{V_g}u^5+\frac{\eta}{V_g}u=0\,; \qquad (1)$$

$$\frac{\partial \varphi_{NL}}{\partial z}+\frac{N}{V_g}u^2=0. \qquad (2)$$

здесь $u=m/\sqrt{2}M_0$ – безразмерная амплитуда спиновой волны, m – значение динамической намагниченности, M_0 – намагниченность насыщения, φ_{NL} – нелинейный фазовый набег, $V_g=\partial\omega/\partial k$ – групповая скорость, $N=\partial\omega/\partial|u|^2$ – нелинейный сдвиг частоты, $\eta=2\pi\gamma\Delta H$ – линейное затухание, $|\gamma|$ = 2.8 МГц/Э – гиромагнитное соотношение, ΔH – полуширина кривой ферромагнитного резонанса, $\upsilon_1=2\pi\gamma\, d\Delta H/d|u|^2$ и $\upsilon_2=2\pi\gamma\, d^2\Delta H/d|u|^4$ параметры затухания третьего и пятого порядка соответственно.

Начнем посторенние теоретической модели с рассмотрения кольцевого резонатора. Как известно для перехода кольцевого резонатора в режим автогенерации монохроматического сигнала необходимо выполнение двух условий. Первое условие (баланс фаз) заключается в синфазном сложении всех циркулирующих в кольце волн, т. е. $k(\omega_{res})l=2\pi n$, где l – длина кольца, n = 1,2,3… соответствует номеру моды с частотой ω_{res}. Связь волнового числа и частоты описывается законом дисперсии рабочих волн в линии задержки $k(\omega)$. Это утверждение справедливо в случае, если электрические длины СВЧ компонентов и соединительных элементов кольца малы по сравнению с электрической длиной спин-волновой линии задержки, что обычно справедливо на практике. Поэтому далее мы считаем, что длина кольца равна длине спин-волновой линии задержки l.

Как было сказано ранее, в результате четырехволновой нелинейности интенсивная спиновая волна демонстрирует сдвиг фазы (2), который происходит путем локального и мгновенного изменения волнового числа. Дополнительный нелинейный фазовый набег нарушает условие баланса фаз, которое в результате будет выполняться на новой частоте $\omega_1=\omega_0+V_g\varphi_{NL}/l$. Это выражение справедливо для достаточно малого изменения фазы сигнала, при котором можно пренебречь наличием дисперсии более высокого порядка ($D=\partial^2\omega(k)/\partial k^2$ и т. д.). В этом случае приведенное ранее соотношение можно представить в эквивалентном виде $\omega_1=\omega\,(k(\omega_0)+\varphi_{NL}/l)$, которое выполняется для каждого периода циркуляции сигнала по кольцу. В переходном процессе установления автоколебаний в кольце амплитуда сигнала возрастет, а вместе с ней увеличивается и φ_{NL}. При этом частота автоколебаний активного кольца ω_{osc} должна удовлетворять соотношению линейной дисперсии для эффективного волнового числа $k(\omega_{res})+\varphi_{NL}/l$, действующему для текущего периода циркуляции сигнала:

$$\omega_{osc}=\omega(k(\omega_{res})+\varphi_{NL}/l), \qquad (3)$$

где частота ω_{res} соответствует выбранной собственной резонансной частоте кольцевого резонатора в линейном режиме.

Для выполнения второго условия (баланса амплитуд) коэффициент усиления разомкнутого кольца T должен быть равен или превышать единицу: $T=\frac{u_i}{u_{i-1}}\geq 1$, где u_i и u_{i-1} – безразмерные амплитуды спиновых волн после i-го и (i-1)-го оборотов сигнала по кольцу. В режиме автогенерации коэффициент усиления разомкнутого кольца должен быть строго больше единицы $T > 1$. Первоначально амплитуда сигнала увеличивается при каждом обороте по кольцу. В результате увеличения нелинейного затухания возрастание амплитуды циркулирующего сигнала ослабевает. После достижения определенного порога амплитуды сигнала в кольце нелинейное затухание ограничивает рост амплитуды, и система достигает динамического равновесия, которое характеризуется установившейся (равновесной) амплитудой сигнала. Данное условие определяется выражением:

$$\frac{u_i(u_{i-1},l)}{u_{i-1}(u_{i-2},l)}=1\,, \qquad (4)$$

где $u_i(u_{i-1},l)$ и $u_{i-1}(u_{i-2},l)$ суть безразмерные амплитуды нелинейных спиновых волн после i-го и (i-1)-го оборотов сигнала по кольцу. В соответствии уравнением (1) эти амплитуды определяются из рекуррентных уравнений, включающих значения амплитуды на предыдущих оборотах сигнала по кольцу. В режиме монохроматической автогенерации оба условия баланса фаз и амплитуд должны выполняться только для одной резонансной моды. Стоит отметить, что особенностью исследуемой системы является ее гибридный характер, что отличает ее от резонаторов стоячей волны. Это обусловлено конструкционными особенностями кольцевой резонансной системы, которая состоит из усилителя, работающего в линейном режиме, и спин-волновой линии задержки, нелинейность которой является насыщаемой.

Используя приведенные выше рассуждения, в исследуемой системе целесообразно рассмотреть эволюцию амплитуды и фазы сигнала по отдельности, считая, что для выбранной гармоники условие баланса фаз выполняется на каждом обороте. Предположим, что в кольце циркулирует СВЧ сигнал малой произвольной амплитудой. Форма этого сигнала не важна, например, это может быть случайный шумоподобный сигнал (при проведении численных расчетов этот сигнал будет использован для проведения численного моделирования с учетом собственного шума системы). Для начала рассмотрим первый оборот СВЧ сигнала по кольцу, который можно условно разделить на несколько этапов.

Входной информационный сигнал формируется генератором сигнала произвольной формы (ГСПФ на рис. 1*б*) в виде двоичной последовательности. Эта последовательность подаётся на управляющий порт электронного аттенюатора. В этом случае граничные значения управляющих напряжений рассматриваются как двоичные значения «0» и «1». Аттенюатор под воздействием двоичной последовательности переключает эффективный коэффициент усиления в кольце между двумя состояниями. С технической точки зрения, увеличение управляющего напряжения снижает коэффициент передачи мощности аттенюатора H_{EA}. В частности, состояние «0» соответствует минимальному значению управляющего напряжения. При этом аттенюатор открыт и не вносит потерь в СВЧ тракт (H_{EA} = 1). В свою очередь, состояние «1» соответствует большей величине управляющего напряжения, которое подается на вход электронного аттенюатора. Это приводит к снижению коэффициента передачи (H_{EA} <1), а следовательно, и к уменьшению амплитуды сигнала, которая будет определяется как $u_{II} = u_{in}\sqrt{H_{EA}}$. Отметим, что здесь и далее будет использоваться понятие безразмерной амплитуды для всей длины кольца. Сигнал во всех точках кольца (см. рис. 1.б), представляет собой электромагнитную волну, которая на спин-волновых преобразователях, показанных на рис. 1*б* пунктирной линией, преобразуется в спиновую волну на входе и обратно в электромагнитную волну на выходе. Использование коэффициента передачи по мощности устраняет проблему различных единиц измерения для амплитуд электромагнитных и спиновых волн, поскольку безразмерная мощность может быть найдена как квадрат безразмерной амплитуды. Однако такой подход нельзя применить для скалярной амплитуды u, входящей в уравнение (1). Стоит напомнить, что эта величина определяет значение нелинейного фазового сдвига φ_{NL}, накопленного спиновой волной, при определенном значении нелинейного коэффициента N, найденного с помощью теории [16]. Таким образом, коэффициенты H_{in} и H_{out}, которые будут введены ниже, должны обеспечивать правильное преобразование безразмерной амплитуды электромагнитной волны в скалярную амплитуду спиновой волны и обратно. Другими словами, скалярная амплитуда u спиновой волны не соответствует квадратному корню из нормированной мощности спиновой волны. Ее значение должно согласовываться с единицами измерения N в уравнении (2). Самый простой способ решения – это корректная перенормировка нелинейных коэффициентов N, ν_1 и ν_2. Такой прием позволяет определять безразмерную амплитуду спиновой волны, таким же образом, как и скалярную амплитуду электромагнитной волны. В результате такого подхода переопределение коэффициентов H_{in} и H_{out} не потребуется.

Рассмотрим распространение сигнала через элементы МАКО, представленного на рис. 1*б*. СВЧ сигнал с амплитудой $u_{II} = u_{in}\sqrt{H_{EA}}$ подается на вход микрополосковой антенны, которая возбуждает поверхностную спиновую волну. Обозначим H_{in} как коэффициент преобразования мощности СВЧ сигнала в квадрат амплитуды спиновой волны. Тогда амплитуда сигнала в этой точке имеет следующий вид: $u_{III} = u_{in}\sqrt{H_{EA}H_{in}}$. Спиновая волна с амплитудой u_{III} распространяется от микрополосковой антенны вдоль пленки ЖИГ и достигает выходной антенны. Амплитуда волны в этой точке находится путем решения дифференциального уравнения (1) для $z = l$ и $u_0 = u_{III}$. В результате амплитуда спиновой волны на выходной антенне рассчитывается как $u_{IV} = u(u_{III}, l) = u(u_{in}\sqrt{H_{EA}H_{in}}, l)$. В этой же точке сигнал, переносимый поверхностной спиновой волной, преобразуется обратно в СВЧ сигнал. Коэффициент обратного преобразования такой же, как и для входной антенны ($H_{out} = H_{in}$) [17]. Запишем амплитуду сигнала на выходе антенны в виде $u_V = u(u_{in}\sqrt{H_{EA}H_{in}}, l)\sqrt{H_{out}}$. Затем, в соответствии с рис. 1*б*, сигнал поступает на вход СВЧ-усилителя: $u_{VI} = u(u_{in}\sqrt{H_{EA}H_{in}}, l)\sqrt{H_{out}G_A}$, где G_A – коэффициент усиления СВЧ усилителя. На заключительном этапе направленный ответвитель используется для отведения небольшой части мощности СВЧ сигнала. Обозначим коэффициент связи по мощности направленного ответвителя за κ. Тогда амплитуда сигнала на выходе определяется следующим выражением: $u_{VII} = u(u_{in}\sqrt{H_{EA}H_{in}}, l)\sqrt{H_{out}G_A\kappa}$. Оставшаяся часть сигнала $u_{VIII} = u(u_{in}\sqrt{H_{EA}H_{in}}, l)\sqrt{H_{out}G_A(1-\kappa)}$ складывается с u_{in} (напомним, что u_{in} представляет собой внутренний шум системы). Таким образом формируется новый сигнал $u_{in2} = u_{in} + u(u_{in}\sqrt{H_{EA}H_{in}}, l)\sqrt{H_{out}G_A(1-\kappa)}$, поступающий на вход электронного аттенюатора.

Для описания переходных процессов в исследуемой системе необходимо повторить рассмотренные выше этапы распространения сигнала для каждого следующего оборота сигнала в кольце. Этот подход позволяет рассчитывать не только эволюцию сигнала при распространении в спин-волновом кольце, но и эволюцию сигнала на выходе. Для этого необходимо рассчитывать мощность выходного сигнала u_{VIII}^2 после каждого оборота по кольцу. Период оборота сигнала по кольцу совпадает со временем задержки сигнала τ. В результате программа численного расчета, созданная по приведенному алгоритму, позволяет рассчитывать временные зависимости мощности на выходе кольцевого резонатора.

III. Моделирование переходных процессов в магнонных активных кольцевых осцилляторах

Перейдем теперь к исследованию переходных процессов в магнонном активном кольцевом осцилляторе. В качестве первого этапа исследований рассмотрим процесс перехода системы режим автогенерации. Для расчета будем использовать параметры аналогичные магнонной резервуарной системе, экспериментально исследованной в статье [5]: внешнее магнитное поле H = 1780 Э, намагниченность насыщения пленки ЖИГ $4\pi M_s$ = 1990 Гс, ширина кривой ферромагнитного $\Delta H = 0.5$ Э, толщина пленки ЖИГ L = 5,65 мкм, расстояние между спин-волновыми антеннами l = 7,7 мм, коэффициенты нелинейного затухания третьего $\nu_1 = 2$ нс$^{-1}$ и пятого $\nu_2 = 2$ пс$^{-1}$ порядков, частота автогенерации, определяемая из условий баланса фаз и амплитуд, f_0 = 7.28 ГГц. Для предложенной структуры расчет, проведенный согласно работе [17], дает H_{in} =

$H_{out} \approx$ 0,5. На рис. 2 представлена смоделированная динамика МАКО за 45 мкс.

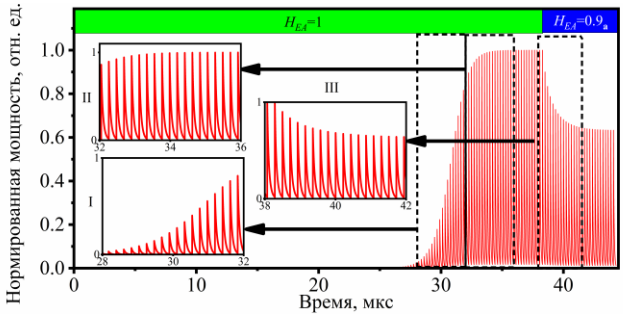

Рис. 2. Переходной процесс в магнонном активном кольцевом осцилляторе. Вставка I показывает нарастание амплитуды автоколебаний; II показывает переход в установившееся состояние. Вставка III показывает уменьшение амплитуды автоколебаний, вызванное внесением дополнительного ослабления в систему

Будем считать, что кольцо замыкается в момент t=0. Как видно из рис. 2, поведение амплитуды сигнала представляет собой последовательность резких скачков вверх, за которыми следует постепенный квазиэкспоненциальный спад амплитуды сигнала. Этот процесс соответствует затуханию сигнала, распространяющегося в спин-волновой линии задержки, а его длительность – времени задержки (τ = 215 нс). Положение скачка амплитуды соответствует моменту времени прохождения сигнала через СВЧ усилитель. В начале развития автоколебаний (t < 32 мкс, см. вставку I на рис. 2) после каждого оборота сигнала в кольце наблюдается увеличение его амплитуды. На этом этапе работы механизм релаксации колебаний обусловлен только линейным затуханием. Коэффициент усиления усилителя превышает затухание, вносимое линейной спин-волновой линией задержки, что приводит к увеличению амплитуды сигнала в 1,3 раза по сравнению с амплитудой на предыдущем обороте. Как видно из рис. 2 в момент времени t = 32 мкс амплитуда сигнала возрастает до уровня, при котором начинает проявляться нелинейное затухание. При t > 32 мкс (см. вставку II на рис. 2) в результате нелинейного затухания возрастание амплитуды сигнала замедляется и, в конечном итоге, она стабилизируется на некотором определенном уровне. Амплитуда автоколебаний в этом состоянии определяет мощность сигнала, генерируемого МАКО. Как видно из рис. 2 стабилизация амплитуды автоколебаний наблюдается при t = 35 мкс. В этом случае потери, вносимые как линейным, так и нелинейным затуханием, полностью компенсируют усиление, вносимое усилителем.

Далее был исследован динамический отклик МАКО на воздействие, обеспечиваемое резким уменьшением коэффициента передачи электронного аттенюатора. В расчете коэффициент передачи уменьшался в момент времени t = 38,2 мкс до значения H_{EA} = 0.9. Это приводило к снижению эффективного коэффициента усиления, что вызывает нарушение равновесия между усилением сигнала и его нелинейным затуханием (см. вставку III к рис. 2). В результате запускается переходной процесс постепенного уменьшения амплитуды автоколебаний до нового установившегося состояния, при котором усиление в кольце вновь компенсирует потери, вызванные как линейным, так и нелинейным затуханием.

Таким образом, при подаче двоичного информационного сообщения в резервуарной вычислительной системе запускается последовательность переходных процессов. На рис. 3 показан результат работы программы для информационной последовательности, состоящей из 90 бит.

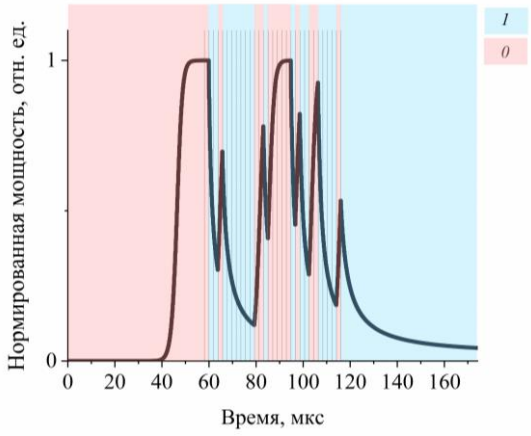

Рис. 3. Динамика выходного сигнала на двоичную последовательность, состоящую из 90 бит

На рис. 3 интервал времени, на котором на вход подается "1" показан голубым, а "0" – розовым цветами. Первые 30 бит содержат "0". Далее в момент времени t = 58.05 мкс на вход подается следующие 30 бит "011011111110010000010110011110". Каждый момент времени, в который начинает действовать следующий бит этой последовательности показан на рис. 3 вертикальной линией. После окончания действия последовательности в момент времени 116.1 мкс на вход подается 30 единичных бит общей длительностью 58,05 мкс. Длительность каждого бита на входе в резервуар составляет 1935 нс. Как видно из рис. 3 первые 30 бит, обеспечивают переход МАКО в режим установившихся автоколебаний с высоким уровнем сигнала. Далее динамика выходного сигнала определяется не только предыдущим значением, сигнала поданного на вход, но и предыстории этого сигнала. Это свойство МАКО реализует нелинейно связанные состояния, лежащие в основе работы резервуара. Заключительные единичные биты переводят кольцо в состояние с низким уровнем установившихся автоколебаний.

IV. Заключение

Переходные процессы, возникающие в МАКО под влиянием информационного сообщения, поданного на вход в управляемый аттенюатор, определяют динамику резервуарной вычислительной системы. Показано образование двух установившихся уровней выходной мощности, плавное переключение между которыми достигается путем изменения коэффициента усиления. В данной работе представлен алгоритм программы, описывающей динамику, наблюдаемую на выходе МАКО в ответ на информационное сообщение, поданное на вход. В основе численной модели лежит уравнение Гинзбурга–Ландау, описывающее нелинейный набег фазы и нелинейное затухание рабочих спиновых волн. В программе результат решения уравнения для нелинейной спин-волновой амплитуды используется в качестве входного сигнала для каждого следующего оборота, при этом на вход резервуара подается информационный

сигнал, регулирующий коэффициент усиления в кольце. Такой принцип работы программы позволяет исследовать динамику резервуаров с временным мультиплексированием. Проверка адекватности модели была выполнена в недавней статье [18]. Результаты сопоставления экспериментальных и теоретических характеристик продемонстрировали хорошее совпадение. Позднее представленная теоретическая модель была использована для исследования влияния различных параметров МАКО на производительность вычислительной системы [19]. Оценки эффективности систем резервуарных вычислений на МАКО проводилась путем расчета емкостей тестов кратковременной памяти и контроля четности. Использование предложенной теоретической модели позволило увеличить значения емкостей этих тестов до величин 3,97 и 2,6 соответственно. Эти величины в два раза превышают значения емкостей до оптимизации.

СПИСОК ЛИТЕРАТУРЫ

[1] Mandic D.P., Chambers J.A. Recurrent Neural Networks for Prediction Learning Algorithms, Architectures and Stability. Wiley Online Library, 2001. 304 p.

[2] Tanaka G., Yamane T., Héroux J. B., Nakane R., Kanazawa N., Takeda S., Numata H., Nakano D., Hirose, A. Recent advances in physical reservoir computing: A review. *Neural Networks*, 2019. 115, 100-123. DOI: 10.1016/j.neunet.2019.03.005

[3] Jaeger H. Tutorial on training recurrent neural networks, covering BPPT, RTRL, EKF and the echo state network approach. Technical Report GMD, Report 159, German National Research Center for Information. 2002. Available at: https://staff.fmi.uvt.ro/~daniela.zaharie/am2016/proiecte/tehnici/ReservoirComputing/ESNTutorialRev.pdf

[4] Watt S., Kostylev M. Reservoir computing using a spin-wave delay-line active-ring resonator based on yttrium-iron-garnet film. *Physical Review Applied*. 2020. 13. P. 034057. DOI: 10.1103/PhysRevApplied.13.034057

[5] Watt S., Kostylev M., Ustinov A. B. Enhancing computational performance of a spin-wave reservoir computer with input synchronization. *Journal of Applied Physics*. 2021. 129. P. 044902. DOI: 10.1063/5.0033292

[6] Watt S., Kostylev M., Ustinov A. B., Kalinikos, B. A.Implementing a magnonic reservoir computer model based on time-delay multiplexing. *Physical Review Applied*. 2021. 15. P.064060. DOI: 10.1103/PhysRevApplied.15.064060.

[7] Chumak A.V. et al., Advances in Magnetics Roadmap on Spin-Wave Computing. *IEEE Transactions on Magnetics*, 2022. 58, pp. 1-72. DOI: 10.1109/TMAG.2022.3149664.

[8] Scott M.M., Patton C.E., Kostylev M.P., Kalinikos B.A. Nonlinear damping of high-power magnetostatic waves in yttrium–iron–garnet films. *Journal of applied physics*. 2004. 95. pp. 6294-6301. DOI: 10.1063/1.1699503.

[9] Ustinov A.B., Kalinikos B.A. Power-dependent switching of microwave signals in a ferrite-film nonlinear directional coupler. *Applied physics letters*. 2006. 89. P. 172511. DOI: 10.1063/1.2362576.

[10] Ustinov A.B., Kalinikos B.A. Ferrite-film nonlinear spin wave interferometer and its application for power-selective suppression of pulsed microwave signals. *Applied physics letters*. 2007. 90 P. 252510. DOI: 10.1063/1.2751121.

[11] Ustinov A.B., Kalinikos B.A. A microwave nonlinear phase shifter. *Applied Physics Letters*. 2008. 93. P. 102504. DOI: 10.1063/1.2980022.

[12] Hansen U.H., Demidov V.E., Demokritov S.O. Dual-function phase shifter for spin-wave logic applications. *Applied Physics Letters*. 2009. 94. P. 252502. DOI: 10.1063/1.3159628.

[13] Ustinov A.B., Drozdovskii A.V., Kalinikos B.A. Multifunctional nonlinear magnonic devices for microwave signal processing. *Applied physics letters*. 2010. 96. P.142513. DOI: 10.1063/1.3386540

[14] Ustinov A.B., Kalinikos B.A., Lähderanta E. Nonlinear phase shifters based on forward volume spin waves. *Journal of Applied Physics*. 2013. 113. P. 113904. DOI: 10.1063/1.4795165.

[15] Ustinov A.B., Kuznetsov N.A., Haponchyk R.V., Lähderanta E., Goto T., Inoue M. Induced nonlinear phase shift of spin waves for magnonic logic circuits. *Applied Physics Letters*. 2021. 119. P. 192405. DOI: 10.1063/5.0074824.

[16] Zvezdin A.K., Popkov A.F. Contribution to the nonlinear theory of magnetostatlc spin waves. *Sov. Phys. JETP*. 1983. 57. P. 350 (1983). Available at: http://jetp.ras.ru/cgi-bin/e/index/e/57/2/p350?a=list

[17] Dmitriev V.F., Kalinikos B.A. Excitation of propagating magnetization waves by microstrip antennas. *Soviet Physics Journal*. 1988. 31. pp. 875–898. DOI :10.1007/BF00893541.

[18] Nikitin A.A., Nikitin A.A., Ustinov A.B., Watt S., Kostylev M.P. Theoretical model for nonlinear spin-wave transient processes in active-ring oscillators with variable gain and its application for magnonic reservoir computing. *Journal of Applied Physics*. 2022. 131. P. 113903. DOI: 10.1063/5.0081142.

[19] Kondrashov A.V., Nikitin A.A., Nikitin A.A., Kostylev M., Ustinov A.B., Numerical simulation of performance of magnonic reservoir computer based on active-ring oscillator. *Journal of Magnetism and Magnetic Materials*. 2022. 563, P.169968. DOI: 10.1016/j.jmmm.2022.169968.

Возможность применения теории мультиопераций для построения самообучающихся систем искусственного интеллекта со свойством объяснимости

С. И. Тодиков
Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» им. В.И. Ульянова (Ленина)
sergeytodikov@gmail.com

***Аннотация*. При разработке систем искусственного интеллекта одним из важных аспектов является более точное описание рассматриваемых событий и их неопределенностей. На сегодняшний день большинство математических аппаратов, на которых построены современные решения, имеют существенный недостаток – вся информация рассматривается только между двумя логическими элементами – истина и ложь. В связи с этим невозможно дать более качественное описание рассматриваемых событий и их неопределенностей. Другим важным аспектом систем ИИ является свойство объяснимости, так как при принятии ключевых решений необходимо объяснение того, как система ИИ пришла к своему ответу. Одним из путей решения является использование теории мультиопераций. В работе представлена методика для построения самообучающихся систем объяснимого искусственного интеллекта на основе теории мультиопераций и показан абстрактный пример применения разработанной методики для построения системы ИИ медицинского характера.**

Ключевые слова: искусственный интеллект, мультиоперация, методика, алгебра, система включений

I. Введение

На сегодняшний день одной из актуальных задач является создание систем искусственного интеллекта (ИИ). При построении систем ИИ важным аспектом является модель представления знаний, которая может позволить дать более качественное описание рассматриваемых событий для ИИ, включая различные степени неопределенности данных. В настоящее время большинство систем ИИ использует нечеткую логику или многозначные классические логики. Проблема этого подхода заключается в том, что вся неопределенность рассматривается только между двумя логическими состояниями – истина и ложь. Это делает невозможным создание более качественных описаний событий и их неопределенностей.

Другим важным аспектом при построении систем ИИ является свойство объяснимости. Множество решений, применяющих алгоритмы ИИ, представляют собой подобие «черного ящика». Зачастую не только конечные пользователи, но и сами разработчики не могут точно определить, как именно модель машинного обучения пришла к тем или иным выводам в ходе обработки исходных данных. Сегодня ИИ применяется в различных областях, таких как здравоохранение, финансы, безопасность и т.д., и при принятии ключевых решений в этих областях важно понимать, как система ИИ пришла к окончательному результату.

В данной работе для решения вышеописанных проблем предлагается в качестве математического аппарата использовать теорию мультиопераций. Теория мультиопераций относиться к теории функциональных систем. В последние несколько десятилетий теория мультиопераций активно развивается. В работе предлагается разработанная методика для построения самообучающихся систем объяснимого ИИ с различными формами неопределенности на основе теории мультиопераций.

II. Основные понятия

Пусть 2^A – множество всех подмножеств A. Отображение из A^n в 2^A называется n-местной мультиоперацией на A. Множество всех n-местных мультиопераций на A будем обозначать через M_A^n. При $|A| = k$ будем использовать обозначение M_k^n. Мультиоперации заданные на k-элементном множестве A будем называть мультиоперациями ранга k. Используем также обозначения

$$M_A = \bigcup_{n\geq 0} M_A^n; \quad M_k = \bigcup_{n\geq 0} M_k^n$$

Следуя [1], n-местную мультиоперацию f на множестве $A = \{a_0, \dots, a_{k-1}\}$ будем представлять, как отображение:

$$f: \{2^0, \dots, 2^{k-1}\}^n \to \{0, 2^0, \dots, 2^{k-1}\}$$

используя следующую кодировку:

$$a_i \to 2^i, \{\emptyset\} = 0, \{a_{i_1}, \dots, a_{i_s}\} = 2^{i_1} + \dots + 2^{i_s}$$

Также n-местную мультиоперацию f можно представить в виде вектора всех её значений $(a_1, \dots, a_{k^n})$, где $a_i \in \{0, 1, \dots, 2^k - 1\}$ и $a_i = f(2^{i_1}, \dots, 2^{i_n})$, а $(i_1, \dots, i_n)$ есть представление $i - 1$ в системе счисления по основанию k n-разрядным числом.

Определим следующие мультиоперации:

- n-местная пустая мультиоперация
$$\theta^n(a_1, \dots, a_n) = \emptyset$$
- n-местная полная мультиоперация
$$\pi^n(a_1, \dots, a_n) = A$$

- *n*-местная мультиоперация проекции по *i*-му аргументу

$$e_i^n(a_1, \dots, a_n) = \{a_i\}$$

Определим следующие метаоперации:

- суперпозиция

$$(f * f_1, \dots, f_n)(a_1, \dots, a_m) = \bigcup_{b_i \in f_i(a_1, \dots, a_m)} f(b_1, \dots, b_n)$$

- разрешимость

$$(\mu_i f)(a_1, \dots, a_n) = \{x | x_i \in f(a_1, \dots, a_{i-1}, a, a_{i+1}, \dots, a_n)\}$$

- пересечение

$$(f \cap g)(a_1, \dots, a_n) = f(a_1, \dots, a_n) \cap g(a_1, \dots, a_n)$$

Определение 1. Алгеброй мультиопераций ранга *k*, размерности *n* называется любое подмножества $B \subseteq M_k^n$, содержащее все n-местные проекции, пустую, полную *n*-местную мультиоперацию и замкнутое относительно метаопераций суперпозиции, разрешимости и пересечения.

Определение 2. Минимальной алгеброй называется алгебра, которая в качестве подалгебр содержит только саму себя и наименьшую.

Определение 3. Наименьшей алгеброй называется алгебра, у которой нет других подалгебр отличных от ее самой.

Определение 4. Полной алгеброй мультиопераций ранга k размерности n называется алгебра, состоящая из всех мультиопераций M_k^n.

Согласно [2], определим терм с множеством неизвестных X и множеством констант K над множеством мультиопераций $F \subseteq M_k$ следующим образом:

1. если $y \in K \cup X$, то $t \equiv y$ – это терм и $U(t) = \{y\}$
2. если $y \in F^n$ и $t_1, \dots, t_n$ являются термами, то $t \equiv f(t_1, \dots, t_n)$ – это терм и $U(t) = U(t_1) \cup \dots \cup U(t_n)$
3. если t_0 терм, $U(t_0) = \{y_1, \dots y_n\}$ и $t_1, \dots, t_n$ являются термами, то $t \equiv t_0(t_1, \dots, t_n)$ – это терм и $U(t) = U(t_1) \cup \dots \cup U(t_n)$.

Общая формула системы включений с неизвестными в теории мультиопераций имеет следующий вид:

$$\begin{cases} t_1(\tilde{c}, \tilde{z}) \subseteq q_1(\tilde{c}, \tilde{z}) \\ \dots\dots\dots\dots\dots\dots\dots\dots \\ t_m(\tilde{c}, \tilde{z}) \subseteq q_m(\tilde{c}, \tilde{z}) \end{cases}$$

где t_i, q_i термы с неизвестными $\tilde{z}$ и константами $\tilde{c}$ в $F \subseteq M_k$

Решением системы включений является набор мультиопераций $f_1, \dots, f_s$ таких, что все i выполняют включения при стандартном определении значения термов с помощью введенного оператора суперпозиции:

$$t_i(\tilde{c}, f_1(\tilde{c}), \dots, f_s(\tilde{c})) \subseteq q_i(\tilde{c}, f_1(\tilde{c}), \dots, f_s(\tilde{c}))$$

III. Возможность применения теории мультиопераций для прикладных задач

Теория мультиопераций является обобщением для теории операций и теории булевых функций. Из этого следует, что размер алгебр мультиопераций будет больше, чем в теории операций и теории булевых функций. Для того чтобы понять, возможно ли использовать бинарные мультиоперации ранга 3 для прикладных задач, необходимо рассмотреть нижний слой решетки алгебр мультиопераций ранга 3. Нижним слоем такой решетки являются минимальные алгебры. К примеру, если размер минимальных алгебр будет равен хотя бы 1000 мультиопераций, то использование такого математического аппарата не имеет смысла, так как для практических задач необходимо выбирать оптимальное множество с наименьшим числом мультиопераций. В таком случае большая часть мультиопераций будет просто впустую заполнять память компьютера, а при определенных алгоритмах с обработкой данных может негативно сказаться на скорости выполнения программы.

Для того, чтобы обнаружить минимальные алгебры бинарных мультиопераций ранга 3, как минимум, необходимо породить алгебры от 134 217 728 бинарных мультиопераций, где размер каждой алгебры лежит в диапазоне от 6 (наименьшая алгебра) до 134 217 728 (полная алгебра).

В работе [3] был разработан алгоритм для поиска всех минимальных алгебр бинарных мультиопераций ранга 3, с помощью которого удалось получить описание всех минимальных алгебр. Количество таких алгебр оказалось 18 штук, а размер таких алгебр лежит в диапазоне от 7 до 30 мультиопераций. Согласно результатам [3] можно сделать вывод о том, что бинарные мультиоперации ранга 3 можно использовать для решения прикладных задач.

В работе [4] показывается, что в теории мультиопераций не выполняется тождество суперассоциативности, а верно только тождество полусуперассоциативности. Это говорит о том, что при использовании различных замыканий, конечные замкнутые множества могут различаться. Важным был вопрос о том, действительно при различных замыканиях будут получаться различные замкнутые множества на одном и том же наборе данных.

Теорема 1. Для всех рангов более 2 существует мультиоперация, для которой простое замыкание является собственным подмножеством обобщенного замыкания.

Теорема 1 говорит о том, что действительно различные замыкания будут давать различные замкнутые множества на одном и том же наборе данных для ранга 3 и выше. Из этого следует, что для мультиопераций ранга 3 и выше невозможно использовать готовые методы и алгоритмы из теории функциональных систем, так как свойство суперассоциативности не выполняется, вследствие чего могут получиться различные замкнутые множества.

Из всего вышеописанного можно сделать два вывода:

1. Теорию мультиопераций ранга 3 можно применять для решения практических задач.

2. При применении теории мультиопераций ранга 3 и выше необходимо разрабатывать новые методы и алгоритмы.

IV. Применение теории мультиопераций для построения самообучающихся систем ИИ со свойством объяснимости

На основе полученного результата в работе [4] в работе [2] был придуман алгоритм для решения систем включений с неизвестными в теории мультиопераций. Для разработанного алгоритма была реализована компьютерная программы для решения систем включений [5]. С использованием разработанной программы была предложена методика для построения самообучающихся систем объяснимого ИИ с различными формами неопределенности на основе теории мультиопераций. В качестве примера рассмотрим применения разработанной методики для построения системы медицинского характера. Концепция системы с использование разработанной методики представлена на рис. 1.

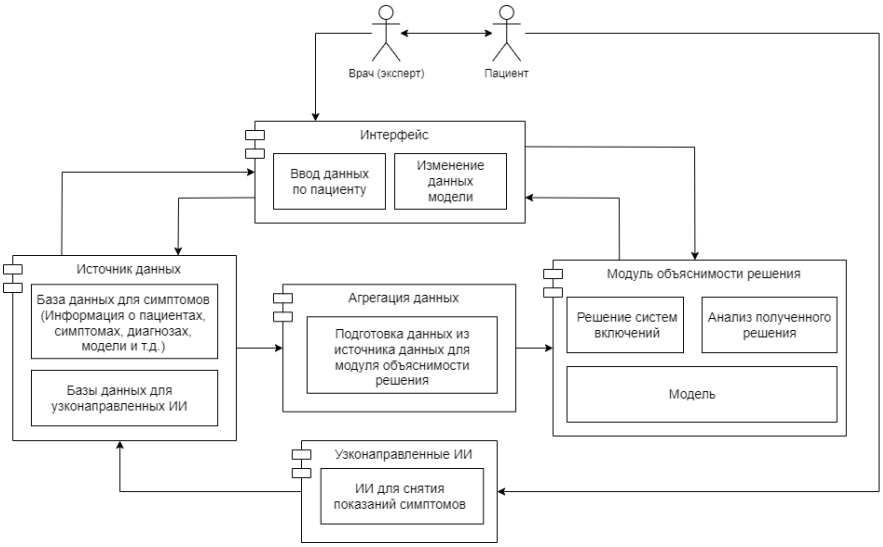

Рис. 1. Концепция построения самообучающейся системы объяснимого ИИ

Концепция состоит из 5 модулей:

1. Источник данных – база данных, в которых хранятся данные о пациентах, симптомах, модели и т. д.
2. Узконаправленные ИИ – ряд ИИ, которые снимают показания физиологических параметров с пациента. Например, мимику, состояние глаз, качество сна и т. д.
3. Агрегация данных – подготовка данных из БД в модуль объяснимости решения.
4. Модуль объяснимости решения – модуль, в котором формируется конечный результат, то есть каким диагнозом болен пациент, и объяснение результата, то есть, почему именно им. Также данный модуль за счет анализа общего решения может показать информацию на некоторые вопросы, например, имеет модель достаточность или недостаточность данных.
5. Интерфейс – модуль, через который взаимодействует эксперт со всей системой.

При первом запуске такой системы эксперт формирует модель в модуле объяснимости решения. Модель состоит из двух множеств: диагнозы и симптомы; и системы включений, на основе которой формируется решение. После каждого редактирования модели, блок решения систем включений ищет общее решение для системы включений и передает его в блок анализа полученного решения, который указывает на недостатки модели (достаточность и однозначность данных, оптимизация модели, наличие противоречий и т. д.) и предлагает редактировать модель, или же принимает новую модель, если все корректно.

Когда модель готова, эксперт может вносить в источник данных физиологические параметры пациента сам, если данные – это одноразовые измерения и могут быть записаны в форме числа и/или текста (например, температура, пульс и т. д.), или же с помощью узконаправленных модулей ИИ, если данные собираются с течением времени и/или подлежат предварительной обработке и/или анализу (например, качество сна, мимика лица и т. д.). После получения всех физиологических параметров пациента, модуль агрегации данных формирует данные из источника данных в специальный вид для модуля объяснимости решения. Каждый физиологический параметр, который приходит из источника данных в модуль агрегации данных, может быть преобразован в ряд симптомов. Например, пульс можно разбить на три симптома: пониженный, нормальный, повышенный; и для разных диагнозов необходимо рассматривать разные состояния пульса. На основе значения физиологического параметра для каждого симптома, который связан с физиологическим параметром, определяется его состояние. Для описания состояний симптомов была разработана специальная модель представления знаний на основе теории мультиопераций ранга 3:

Модель для симптомов:

0 – {∅} – не эксперт по текущему симптому;

1 – {1} – симптома нет;

2 – {2} – симптом есть;

3 – {1,2} – неопределенно;

4 – {4} – невозможно определить состояние симптома (нет входных данных по симптому или не валидные данные по симптому);

5 – {1,4} – симптома нет или невозможно определить состояние симптома;

6 – {2,4} – симптом есть или невозможно определить состояние симптома;

7 – {1,2,4} – нужны уточнения.

После того, как каждому симптому установлено соответствующее состояние, данные переходят в модуль объяснимости решений. В этом модуле на основе состояний симптомов, которые приходят из модуля агрегации данных, в блоке решения систем включений происходит поиск частичного решения, результатом которого является определение состояний для каждого диагноза. Для описания состояний диагнозов была разработана следующая модель представления знаний на основе теории мультиопераций ранга 3.

Модель для диагнозов:

0 – {∅} – не эксперт по текущему диагнозу;

1 – {1} – не болеет;

2 – {2} – болеет;

3 – {1,2} – неопределенно;

4 – {4} – невозможно определить состояние диагноза, так как не все симптомы имеются (или не все симптомы валидны);

5 – {1,4} – не болеет или невозможно определить диагноз (не валидные входные данные);

6 – {2,4} – болеет или невозможно определить диагноз (не валидные входные данные);

7 – {1,2,4} – нужны уточнения.

После получения частичного решения блок анализа полученного решения формирует подробное объяснение для результата, то есть объясняет, почему именно такой результат был получен. Далее возможны следующие случаи:

1. Эксперт согласен с решением и утверждается соответствующий диагноз.
2. Эксперт не согласен с решением системы. В этом случае необходимо проанализировать ответ системы и саму модель. Возможно, понадобятся изменения в самой модели: добавление или удаление симптомов, или диагнозов, изменение системы включений.
3. Эксперт не является квалифицированным по некоторым симптомам. В этом случае необходим новый эксперт, который будет квалифицированным специалистом в этих симптомах. Также в этом случае новый эксперт может добавить новую информацию для модели.
4. Не все симптомы имеют валидное значение в источнике данных. Этот случай означает, что ряд узконаправленных ИИ или эксперт допустили ошибку.

Для успешного решения необходимо выйти на случай 1. Если же был получен другой случай, то необходимо произвести модификацию системы с помощью эксперта. Если эксперта найти невозможно, то считается, что данных, которые заложены в системе недостаточно, чтобы определить диагноз пациента. Это есть одно из решений системы.

В целом система формирует следующие три класса решений:

1. диагноз;
2. требование по уточнению или дополнению данных;
3. предложение по усовершенствованию системы знаний.

Преимуществом этой системы является то, что при изменении модели производится анализ обобщенного решения систем включений, который может объяснить, достаточно ли данных для текущей модели или нет, то есть насколько однозначны введенные условия экспертом по каждому диагнозу. Если данных будет недостаточно для модели, то возможно влияние симптомов не только на тот диагноз, для которого они установлены, но и на другие диагнозы.

V. Заключение

В работе было обосновано, что теорию мультиопераций ранга 3 можно применять для прикладных задач, но при этом необходимо разрабатывать новые методы и алгоритмы для работы с мультиоперациями. На основе уже полученных результатов в теории мультиопераций была разработана методика для построения самообучающихся систем объяснимого ИИ с различными формами неопределенности на основе теории мультиопераций. Разработанная методика предлагает три существенных преимущества. Во-первых, возможность дать системе ИИ более качественное описание событий, так как теория мультиопераций позволяет рассматривать события между различными логическими состояниями и их неопределенностями. Во-вторых, разработанная методика позволяет ввести свойство объяснимости, которое позволяет получать информацию о том, как именно система пришла к окончательному результату. В-третьих, система ИИ может помогать эксперту или экспертам в настройке самой системы за счет анализа модели, которая закладывается в систему.

В качестве примера было показано, как можно использовать разработанную методику для построения системы ИИ медицинского характера. Предложенная методика может быть применима в различных практических областях.

Список литературы

[1] Перязев Н.А. Клоны, ко-клоны, гиперклоны и суперклоны // Учен. зап. Казан. гос. ун-та. Серия Физико-математические науки. 2009. Т. 151, кн. 2. С. 120-125.

[2] Peryazev N.A. Systems of Inclusions with Unknowns in Multioperations // Bulletin of Irkutsk State University – Series Mathematics. 2022. V. 38. P. 112-123.

[3] Тодиков С.И. Алгоритм поиска минимальных алгебр бинарных мультиопераций ранга 3 // Современные информационные технологии и ИТ-образование. 2020. Т. 16. № 4. С. 841-850.

[4] Тодиков С.И. Сравнение выразительных возможностей различных языков мультиопераций // Материалы 2-й международной конференции «Информационные технологии, их приложения и информационное образование». 2021. С. 235-242.

[5] Тодиков С.И. Автоматизация процесса решения систем включений с неизвестными в теории мультиопераций // Материалы 7-й международной конференции «Синтаксис и семантика логических систем». 2022. С. 53.

Разработка и программная реализация системы мониторинга и анализа контента на видео и изображениях в интернет-пространстве

М. А. Руденко[1], В. В. Милюков[2], М. А. Крапивина[3], А. В. Руденко[4]
ФГАУО ВО «Крымский федеральный университет им. В.И. Вернадского»
[1]rudenko.ma@cfuv.ru, [2]milyukov.vv@cfuv.ru, [3]miladakrapivina@gmail.com, [4]rudenkoandre@mail.ru

Аннотация. **Статья посвящена исследованию технологии компьютерного зрения и решению задач мониторинга и анализа контента на видео и изображениях в интернет-пространстве. С этой целью получена модель нейронной сети с высокими оценками точности, предложена модель анализа контента на основе комплекса математических метрик**

Ключевые слова: мониторинг, контент, противоправный контент, обработка изображений, анализ метрик, сверточные нейронные сети, YOLO

I. Введение

Сегодня, в эпоху активного развития цифровых технологий, информация стала более доступной, её создание и распространение все более упрощается. Этот факт имеет как и очевидные положительные, так и отрицательные стороны. Согласно последним исследованиям в области СМИ и массовых телекоммуникаций: «Высокая доступность и широкий охват аудитории являются ключевыми факторами использования возможностей социальных медиа различными деструктивными сообществами и организациями (в частности, экстремистскими)» [1].

Современные системы контроля противоправного контента в сети Интернет в большинстве своем опираются на анализ текстового содержимого, проверке всевозможных фильтров и ручном формировании списков ресурсов экспертами. В это же время особенностью экстремистского контента является явная самоидентификация авторов контента. Как правило, экстремистские группировки явно признаются в своих преступлениях, показывают свою атрибутику. К атрибутике, в частности, относятся флаги, эмблемы, нашивки. То есть в экстремистских материалах часто есть ограниченный набор символики на иллюстрирующих изображениях и видео.

В связи с этим актуальной задачей является разработка и программная реализация системы мониторинга и анализа контента на видео и изображениях в интернет-пространстве. Эта система может применяться как самостоятельное решение, и как дополнительный инструмент.

II. Обзор используемых инструментов

В настоящее время разработан целый ряд инструментов и библиотек для обработки изображений и создано множество алгоритмов распознавания изображений.

В последнее время для решения задачи поиска объектов на изображениях широкое распространение получили алгоритмы, основанные на применении региональных глубоких сверточных нейронных сетей (Regional Convolutional Neural Networks, R-CNN) и сетей детектирования YOLO (You Only Look Once), которые принципиально ориентированы на решение указанной задачи с одновременной классификацией найденных объектов. Архитектура YOLO была выбрана как наиболее оптимальное решение по совокупности точности и быстродействия [2, 3].

III. Понятие противоправного контента

Многие страны и межгосударственные организации описывают понятие «противоправного контента» по-разному. Еврокомиссия о мерах по эффективной борьбе с незаконным контентом в Интернете в своих рекомендациях определяет: «незаконный контент означает любую информацию, которая не соответствует законодательству Союза или законодательству соответствующего государства-члена» [4].

Иными словами, противоправным контентом является информация, содержание которой не соответствует законодательству государства.

Особая категория противоправного контента – экстремистские материалы. Материалы, которые призывают к экстремистской деятельности, либо оправдывают ее, являются экстремистскими.

Так, согласно федеральному закону от 25 июля 2002 г. № 114-ФЗ «О противодействии экстремистской деятельности»: «экстремистская деятельность (экстремизм):

- насильственное изменение основ конституционного строя и (или) нарушение территориальной целостности Российской Федерации (в том числе отчуждение части территории Российской Федерации), за исключением делимитации, демаркации, редемаркации Государственной границы Российской Федерации с сопредельными государствами;
- публичное оправдание терроризма и иная террористическая деятельность; …» и «экстремистская организация – общественное или религиозное объединение либо иная организация, в отношении которых по основаниям, предусмотренным настоящим Федеральным законом, судом принято вступившее в законную силу решение о

ликвидации или запрете деятельности в связи с осуществлением экстремистской деятельности» [5].

Экстремистская деятельность, как правило, имеет четкую региональную локализацию, то есть при борьбе с распространением экстремистских материалов важно учитывать географию деятельности таких группировок.

IV. Модель нейронной сети

Применяемая классификация объектов основана на наиболее опасных в РФ и особо актуальных для Республики Крым, ввиду граничного положения с Украиной, и содержит следующие классы:

- ColSwast – свастика (ЦВ);
- GraySwast – свастика (ЧБ);
- Igil – Игил;
- RSector – Правый сектор;
- Taliban – Талибан;
- Ichkeria – Ичкерия;
- Azov – Азов.

Модель обучена на датасете, содержащем 163 изображения с достаточно равномерном распределением по классам (рис. 1) и показывает хорошие результаты точности (рис. 2).

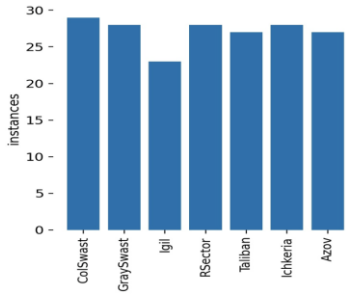

Рис. 1. Распределение классов первой версии обученной модели нейросети

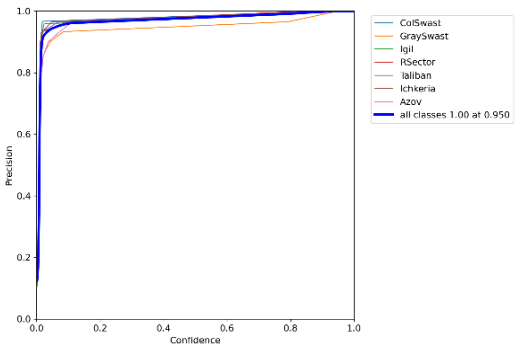

Рис. 2. Точность обученной модели

V. Модель анализа объектов на изображениях и видео

Оригинальные метрики детектирования YOLO:

$$Dyolo = (n, x, y, w, h, confidence), \quad (1)$$

где n – номер класса; x и y – относительные координаты bounding box объекта; w и h – относительные ширина и высота bounding box объекта, соответственно; c – confidence (коэффициент уверенности сети).

На основе этих метрик была разработана модель анализа объектов на изображениях и видео.

Математические метрики рассматриваемой модели: площадь объекта, центр фокусировки объекта, количество объектов, максимальный конфидент, средний конфидент, максимальная площадь, средняя площадь, площадь покрытия, дисперсия абсцисс и дисперсия ординат.

Площадь – метрика для одного отдетектированного объекта. Центр фокусировки, количество объектов, максимальный конфиденс (confidence), площадь покрытия могут считаться не только в рамках одного детектируемого объекта заданного класса, но и для всех найденных объектов одного класса (это происходит, когда в результате отдетектировано несколько изображений). Все остальные считаются в рамках одного класса.

Площадь объекта (S) – геометрическая площадь объекта, представляющее из себя произведение ширины и высоты ограничивающей рамки (bounding box) объекта на отдетектированном изображении. Величина относительна размеру изображения. Площадь объекта явно показывает какую часть от всего изображения занимает отдетектированный объект.

$$= w * h\,, \quad (2)$$

где w – относительная ширина bounding box объекта; h – относительная высота bounding box объекта.

Центр фокусировки (X, Y) – средняя точка центров bounding box найденных объектов; координаты точки – среднее арифметическое относительных координаты bounding box объектов:

$$= \frac{\sum_{k=1}^{n} x_k}{n}\,, \quad (3)$$

где x – относительная абсцисса объекта; n – количество объектов класса.

$$= \frac{\sum_{k=1}^{n} y_k}{n}\,, \quad (4)$$

где y – относительная ордината объекта; n – количество объектов класса.

Если координаты центра фокусировки равны (или очень близки) к координатам (0,5; 0,5) это значит, что объекты (объект) занимают центральное положение на изображении. Чем центральнее находится объект на изображении, тем большую смысловую нагрузку он несет для человеческого восприятия. Если рассматривать интерпретацию значения метрики в предметной области поиска противоправного контента, можно определить следующее: чем ближе центр фокуса отдетектированного объекта к центру фокуса всего изображения, тем более неслучайно нахождение объекта и «более противоправно» само изображение.

Количество объектов (n) – число найденных объектов одного класса или общее число найденных объектов. Эту метрику можно интерпретировать по-разному, к примеру, большое n объектов класса «флаг» может свидетельствовать, что на источнике изображено шествие или парад.

Максимальный конфиденс (C_{max}) – максимальное значение конфиденса для объектов одного класса или для всех найденных объектов. Конфиденс (confidence, коэффициент уверенности) — это метрика качества прогнозирования, которая показывает, на сколько сеть уверена (не уверена) в своих собственных результатах, представляет собой число от 0 до 1 эквивалентное проценту уверенности.

$$= max(Ck)\,, \tag{5}$$

где Ck = {C0, C1, … Cn} последовательность значений коэффициента уверенности объектов. Очевидно, C_{max} может принимать значение от 0 до 1. Если значение максимального конфиденса близко к 1 – это значит, что с высокой точностью распознан как минимум один объект. Значение этой метрики может использоваться как граничное значение определения наличия экстремистского контента. К примеру, если Cmax < 0,3, то на изображениях, скорее всего, нет экстремистского контента.

Средний конфиденс (C_{avg}) – среднее значение конфиденса для объектов одного класса; считается как среднее арифметическое и принимает значение от 0 до 1. Может интерпретироваться как уверенность нахождения класса объекта.

$$= \frac{\sum_{k=1}^{n} Ck}{n}\,, \tag{6}$$

где C – значение коэффициента уверенности объекта; n – количество объектов класса.

Максимальная площадь (S_{max}) – максимальное значение площади для объектов одного класса. Может принимать значение от 0 до 1.

$$= max(S_k)\,, \tag{7}$$

где Sk = {S0, S0, … Sn} последовательность значений площадей объектов.

Средняя площадь (S_{avg}) – среднее значение площади объектов одного класса; считается как среднее арифметическое, принимает значение от 0 до 1.

$$= \frac{\sum_{k=1}^{n} S_k}{n}\,, \tag{8}$$

где S – значение площади объекта; n – количество объектов класса.

Площадь покрытия (S_{com}) – сумма площадей для объектов одного класса или для всех найденных объектов. Так как объекты на изображении могут перекрывать друг друга, возможно, что $S_{com} > 1$. Это свидетельствует о кучности отдетектированных объектов.

$$= \sum_{k=1}^{n} S_k\,, \tag{9}$$

где S – значение площади объекта; n – количество объектов класса.

Дисперсия – это число, равное среднему квадрату отклонений значений случайной величины от ее среднего значения. Здесь считается дисперсия абсцисс и ординат. Чем больше эти значения, тем разрозненней объекты на изображении. Так как координаты – относительные величины, дисперсии также относительны.

Дисперсия абсцисс (D_x) – показывает отклонения объектов от центра фокусировки по оси абсцисс. В случае единичного распознанного изображения принимает значение 0.

$$= \frac{\sum_{k=1}^{n} (x_k - X)^2}{n}\,, \tag{10}$$

где x – относительная абсцисса объекта; X – абсцисса центра фокусировки; n – количество объектов класса.

Дисперсия ординат (D_y) – показывает отклонения объектов от центра фокусировки по оси абсцисс. В случае единичного распознанного изображения принимает значение 0.

$$= \frac{\sum_{k=1}^{n} (y_k - Y)^2}{n}\,, \tag{11}$$

где x – относительная ордината объекта; Y – ордината центра фокусировки; n – количество объектов класса.

VI. Реализация системы мониторинга и анализа контента на видео и изображениях

Предложенные математические модели были реализованы в алгоритмах и программных модулях разработанной системы мониторинга и анализа контента на видео и изображениях (рис. 3).

Модуль анализа принимает заявку в виде JSON-файла, где прописана ссылка на анализируемый ресурс. Модуль предварительной подготовки скачивает все файлы ресурса, фильтрует их по типу, конвертирует оставшиеся изображения и видео в формат, совместимый для детектирования, и запускает детектирование подготовленных ресурсов. В результате детектирования формируется директория с определенной внутренней структурой (рис. 4).

Рис. 3. Структура системы

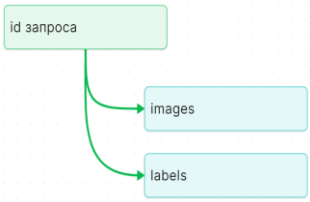

Рис. 4. Структура директории

Модуль анализа метрик принимает расположение директории и в зависимости от содержимого, формирует текстовый отчет.

Рассмотрим две тестовые ситуации: распознано одно изображение (рис. 5, 6, 7) и распознано несколько изображений (рис. 8, 9).

Одно изображение.

Рис. 5. Распознанное изображение

Метрики изображения:

3 0.544156 0.756067 0.228525 0.331402 0.943758

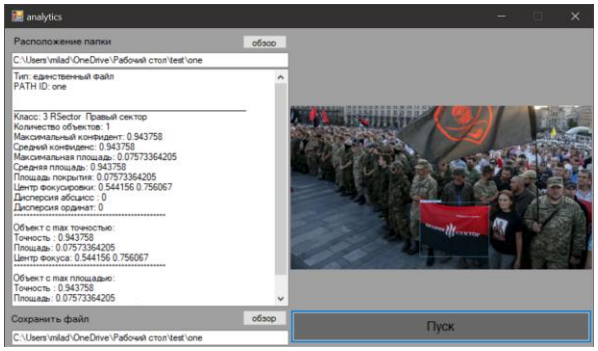

Рис. 6. Интерфейс приложения при одном изображении

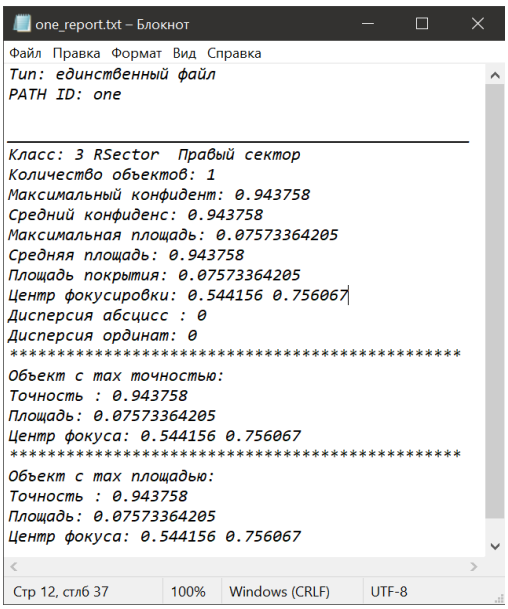

Рис. 7. Отчет по запросу с одним изображением

Несколько изображений.

Пусть распознаны следующие изображения:

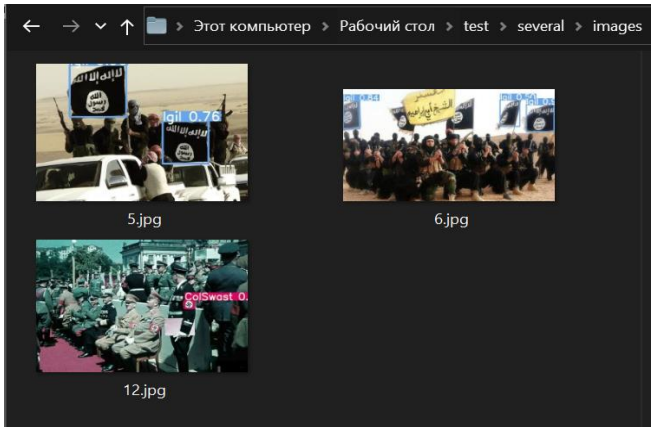

Рис. 8. Распознанные изображения

Текстовые метрики распознанных изображений имеют следующий вид:

5.txt	2	0.70744	0.57326	0.216898	0.307692	0.761032	0.066738
	2	0.29256	0.197802	0.267339	0.377289	0.955227	0.100864
6.txt	2	0.788672	0.216667	0.092969	0.236111	0.499497	0.021951
	2	0.039063	0.230556	0.078125	0.25	0.843372	0.019531
	2	0.932422	0.260417	0.130469	0.243056	0.912715	0.031711
12.txt	0	0.723866	0.48963	0.04142	0.060741	0.896578	0.002516

Так как изображений несколько, стал доступен список изображений с объектами, имеющими максимальные значения конфиденса и площади.

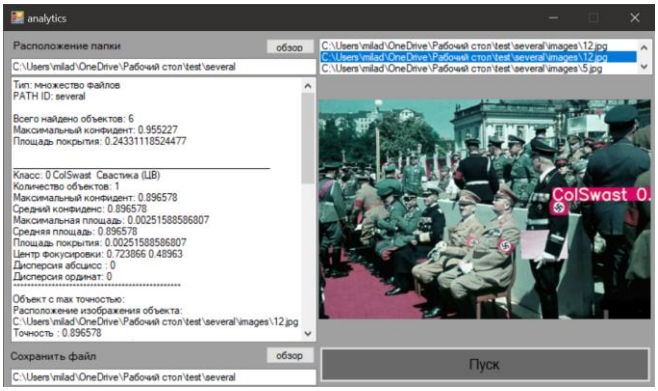

Рис. 9. Интерфейс приложения при нескольких изображениях

Текст отчета:

Тип: множество файлов
PATH ID: several

Всего найдено объектов: 6
Максимальный конфидент: 0.955227
Площадь покрытия: 0.24331118524477

Класс: 0 ColSwast Свастика (ЦВ)
Количество объектов: 1
Максимальный конфидент: 0.896578
Средний конфиденс: 0.896578
Максимальная площадь: 0.00251588586807
Средняя площадь: 0.896578
Площадь покрытия: 0.00251588586807
Центр фокусировки: 0.723866 0.48963
Дисперсия абсцисс : 0
Дисперсия ординат: 0
****

Объект с max точностью:
Расположение изображения объекта:
C:\Users\milad\OneDrive\Рабочий стол\test\several\images\12.jpg
Точность : 0.896578
Площадь: 0.00251588586807
Центр фокуса: 0.723866 0.48963
****
Объект с max площадью:
Расположение изображения объекта:
C:\Users\milad\OneDrive\Рабочий стол\test\several\images\12.jpg
Точность : 0.896578
Площадь: 0.00251588586807
Центр фокуса: 0.723866 0.48963

Класс: 2 Igil Игил
Количество объектов: 5
Максимальный конфидент: 0.955227
Средний конфиденс: 0.7943686
Максимальная площадь: 0.100864063971
Средняя площадь: 0.04815905987534
Площадь покрытия: 0.2407952993767
Центр фокусировки: 0.5520313 0.2957404
Дисперсия абсцисс : 0.11106202297516
Дисперсия ординат: 0.01967168195144
****
Объект с max точностью:
Расположение изображения объекта:
C:\Users\milad\OneDrive\Рабочий стол\test\several\images\5.jpg
Точность : 0.955227
Площадь: 0.100864063971
Центр фокуса: 0.29256 0.197802
****
Объект с max площадью:
Расположение изображения объекта:
C:\Users\milad\OneDrive\Рабочий стол\test\several\images\5.jpg
Точность : 0.955227
Площадь: 0.100864063971
Центр фокуса: 0.29256 0.197802

Аналитические расчеты, представленные в табличной форме на рис. 10, подтверждают корректность вывода модуля анализа.

	class	x	y	h	w	C	S
5.txt	2	0.70744	0.57326	0.216898	0.307692	0.761032	0.066738
	2	0.29256	0.197802	0.267339	0.377289	**0.955227**	**0.100864**
6.txt	2	0.788672	0.216667	0.092969	0.236111	0.499497	0.021951
	2	0.039063	0.230556	0.078125	0.25	0.843372	0.019531
	2	0.932422	0.260417	0.130469	0.243056	0.912715	0.031711
12.txt	0	0.723866	0.48963	0.04142	0.060741	**0.896578**	**0.002516**
общее	6					0.955227	0.243311
класс 0	1	Центр фокуса			Среднее:	0.896578	0.002516
		0.723866	0.48963		Макс:	0.896578	0.002516
		Дисперсия			Площадь покрытия		0.002516
		0	0				
класс 2	5	Центр фокуса			Среднее:	0.811404	0.040552
		0.552031	0.29574		Макс:	0.955227	0.100864
		Дисперсия			Площадь покрытия		0.240795
		0.111062	0.019672				

Рис. 10. Аналитические расчеты метрик отчета для нескольких изображений

Модуль отправки заявки отправляет отчет пользователю, также в виде JSON файла.

VII. Заключение

В результате исследования разработана модель анализа параметров детектированных объектов заданных классов на изображениях и видео, реализовано программное обеспечение, алгоритмически использующее данную модель. Тестирование показало высокую эффективность разработки, что позволяет использовать ее в государственных организациях, в особенности, общеобразовательных учреждениях для анализа контента на предмет наличия в первую очередь противоправного контента.

Список литературы

[1] Карданов А.Р., Карданова Д.А. Экстремистский контент в социальных медиа: анализ основных трендов и мер // Журнал прикладных исследований. 2022. № 11, т.2. С. 169-172.

[2] Руденко М.А., Руденко А.В. Нечеткая модель классификации медицинских изображений на основе нейронных сетей // XXIV Международная конференция по мягким вычислениям и измерениям (SCM-2021): сборник докладов. Санкт-Петербург. 26 – 28 мая 2021 г. СПб.: СПбГЭТУ «ЛЭТИ». 351 с.

[3] YOLOv5: state-of-the-art модель для распознавания объектов. — Текст: электронный // neurohive.io: [сайт]. — URL: https://neurohive.io/ru/papers/yolov5-state-of-the-art-model-dlyaraspoznavaniya-obektov/ (дата обращения: 28.04.2022).

[4] European Commission, Secretariat-General Commission Recommendation (EU) 2018/334 of 1 March 2018 on measures to effectively tackle illegal content online // European Commission, Secretariat-General. 2018. № C/2018/1177. P. 50–61.

[5] Об информации, информационных технологиях и о защите информации: Федеральный закон № 149-ФЗ: [принят Государственной Думой 8 июля 2006 г.: одобрен Советом Федерации 14 июля 2006 г.]. – Текст: непосредственный

СОДЕРЖАНИЕ

Секция 1. Концепции построения гибридного интеллекта

Объяснительный искусственный интеллект в системах поддержки принятия врачебных решений
Е. Н. Волков, А. Н. Аверкин 3

Gradient-based методы объяснительного искусственного интеллекта для классификации заболеваний глаза
Е. Н. Волков, А. Н. Аверкин 7

Алгоритм скользящего управления в сочетании с нейронной сетью для системы электроприводов экзоскелета
Динь Данг Чыонг, Нгуен Динь Хань, Ха Ван Муон 11

Глубокое обучение для ранней диагностики диабетической ретинопатии: исследование с использованием сверточной нейронной сети
Али Султан Маея 15

Цифровизация процесса выявления дефектов на изделиях из силицированного графита с помощью нейронных сетей
И. В. Друмов, М. А. Камнев, Г. С. Малышев, Г. В. Терехин 19

Использование вариационного автокодировщика для расширения обучающего набора нейронной сети, распознающей дефекты на изделиях из силицированного графита
Г. С. Малышев, И. В. Друмов, М. А. Камнев, Г. В. Терехин 22

Искусственные фотонные нейронные сети: принципы построения и способы реализации
М. Е. Белкин, К. В. Шабельник 26

Estimation of Turkish Constitutional Court Decisions in Terms of Admissibility with NLP
Emrah Aydemir 29

Секция 2. Технологии искусственного интеллекта и их приложения

Первые шаги к аппаратной реализации резервуарной вычислительной системы со спайковым выходным слоем на основе органических мемристоров
А. Н. Мацукатова, Н. В. Прудников, В. А. Кулагин, А. Д. Трофимов, А. В. Емельянов 33

Оценка нейросетевого алгоритма повышения точности обработки сигналов с вращающегося трансформатора
Е. Ю. Антонова, Ю. А. Жуков 36

Применение нейросетевых технологий в системах мониторинга и диагностики газовых турбин большой мощности
П. В. Соколов, В. С. Карелин 41

Сравнительный анализ методов обнаружения аномальных режимов работы турбогенератора
П. В. Соколов, И. В. Попов 45

Глубокие пирамидальные нейронные сети быстрого обучения для корреляционной обработки сигналов и изображений
А. Ю. Дорогов 49

Нейросетевое управление параметрами окружающей среды в неонатальных инкубаторах
С. В. Фролов, А. Ю. Потлов, А. А. Коробов, К. С. Савинова 53

Оценка применимости методов машинного обучения для выявления патологии внутренних органов человека по результатам биоэлектрографии
Ю. А. Шичкина, Р. Р. Фаткиева, А. Е. Сычев, М С Прасад, Верма Шивани 57

Возможность визуализации трехмерно звука для оценки локализации его источника
Димитриос Палогианнидис 61

Анализ сообщений в социальных сетях методами искусственного интеллекта
А. М. Лопушанский, Я. А. Бекенева 65
Возможности глубокого обучения применительно к задаче компьютерного моделирования тонкостенных оболочечных конструкций
Ю. Н. Згода 68
Применение нейронной сети для оценки пользовательского опыта работы с приложением
В. А. Юркин, С. Э. Сараджишвили, Н. В. Воинов, С. А. Молодяков 72
Модель иерархической кластеризации субъектов Федерации по уровню их импортозависимости
Е. С. Митяков, А. И. Ладынин, А. Г. Шмелева, Н. А. Мурашова, С. Н. Митяков 76

Секция 3. Управление данными и организация вычислений в интеллектуальных системах

Организация хранения данных для проведения дополнительной диагностики работы при мониторинге компьютерной сети
М. И. Авилов 81
FPGA-реализация деления чисел с фиксированной точкой методом Ньютона–Рафсона
О. И. Буренева, О. Ю. Кайданович 85
Интеллектуальная информационная система и база знаний сушильных установок
С. В. Артемова, А. И. Ладынин, Н. М. Шмелева, М. И. Бесхмельнов, М. А. Каменская 89
Классификация и прогнозирование заболеваний легких по данным рентгенографии грудной клетки
Р. И. Думаев, С. А. Молодяков 92
Подход к определению динамики запаса газа на основе нейронных дифференциальных уравнений
А. К. Петрова 96
Численное моделирование переходных процессов, используемых в магнонных резервуарных вычислениях
Андрей А. Никитин, Алексей А. Никитин, М. П. Костылев, А. Б. Устинов 100
Возможность применения теории мультиопераций для построения самообучающихся систем искусственного интеллекта со свойством объяснимости
С. И. Тодиков 105
Разработка и программная реализация системы мониторинга и анализа контента на видео и изображениях в интернет-пространстве
М. А. Руденко, В. В. Милюков, М. А. Крапивина, А. В. Руденко 109

NEURONT.ETU.RU

197022, Россия,
Санкт-Петербург,
ул. Профессора Попова,
д.5, лит. Ф,
СПбГЭТУ «ЛЭТИ»
Тел.: +7 (812) 346-46-37
E-mail: IRVC.eltech@mail.ru