



ЦЕНТР ДИАГНОСТИКИ
И ТЕЛЕМЕДИЦИНЫ

ISSN 2712-8490 (Print)
ISSN 2712-8962 (Online)

DIGITAL DIAGNOSTICS

Рецензируемый научный медицинский журнал

5 Том | Volume 1 Выпуск | Issue

Искусственный интеллект в медицине

2024



ЭКО • ВЕКТОР

<https://journals.eco-vector.com/DD>

УЧРЕДИТЕЛИ

- ГБУЗ «Научно-практический клинический центр диагностики и телемедицинских технологий ДЗМ»
- ООО «Эко-Вектор»

Свидетельство о регистрации СМИ ПИ
ПИ № ФС 77 - 79539 от 09.11.2020

ИЗДАТЕЛЬ

ООО «Эко-Вектор»

Адрес: 191186, Санкт-Петербург, Аптекарский
переулок, д. 3, литера А, помещение 1Н
E-mail: info@eco-vector.com
WEB: <https://eco-vector.com>

РЕКЛАМА

Отдел рекламы

Тел.: +7 (968) 545 78 20

E-mail: adv2@eco-vector.com

РЕДАКЦИЯ

Зав. редакцией

Елена Андреевна Филиппова

E-mail: ddjournal@eco-vector.com

Тел: +7 (965) 012 70 72

Адрес: 125040, г. Москва,

ул. Расковой, д. 16/26, стр. 1

ПОДПИСКА

Подписка на печатную версию через интернет:

www.journals.eco-vector.com/

www.akc.ru

www.pressa-rf.ru

OPEN ACCESS

В электронном виде журнал распространяется
бесплатно —
в режиме немедленного открытого доступа

ИНДЕКСАЦИЯ

- SCOPUS
- РИНЦ
- Google Scholar
- Ulrich's International Periodicals Directory
- WorldCat

Оригинал-макет

подготовлен в издательстве «Эко-Вектор».

Литературный редактор: А.А. Ридэль

Корректор: А.А. Ридэль

Вёрстка: Ф.А. Игнащенко

Обложка: Е.Д. Бугаенко

Сдано в набор 14.03.2024. Подписано в печать 29.03.2024.

Выход в свет 20.04.2024. Формат 60 × 88%.

Печать офсетная. Печ. л. 17. Усл. печ. л. 15,8.

Уч.-изд. л. 9,3. Тираж 5000 экз.

Цена свободная.

Отпечатано в ООО «Типография Фурсова».

196105, Санкт-Петербург, ул. Благодатная, 69.

Тел.: +7 (812) 646-33-77

16+

© ООО «Эко-Вектор», 2024

ISSN 2712-8490 (Print)

ISSN 2712-8962 (Online)

Digital Diagnostics

Том 5 | Выпуск 1 | 2024

ЕЖЕКВАРТАЛЬНЫЙ РЕЦЕНЗИРУЕМЫЙ НАУЧНЫЙ
МЕДИЦИНСКИЙ ЖУРНАЛ

Главный редактор

Синицын Валентин Евгеньевич, д.м.н., профессор (Москва, Россия)

ORCID: 0000-0002-5649-2193

Заместитель главного редактора

Васильев Юрий Александрович, к.м.н., (Москва, Россия)

ORCID: 0000-0002-0208-5218

Научный редактор

Березовская Татьяна Павловна, д.м.н., профессор (Обнинск, Россия)

ORCID: 0000-0002-3549-4499

Ответственный секретарь

Виноградова Ирина Александровна, к.т.н. (Москва, Россия)

ORCID: 0000-0001-6465-4132

Редакционная коллегия

Berlin L., профессор (Иллинойс, США)

ORCID: 0000-0002-0717-0307

Беляев М.Г., к.ф.-м.н. (Москва, Россия)

ORCID: 0000-0001-9906-6453

Важенина Д.А., д.м.н., доцент (Москва, Россия)

ORCID: 0000-0002-4236-709X

Bisdas S., MD, PhD (Лондон, Великобритания)

ORCID: 0000-0001-9930-5549

Гомболевский В.А., к.м.н. (Москва, Россия)

ORCID: 0000-0003-1816-1315

Доможирова А.С., д.м.н., доцент (Москва, Россия)

ORCID: 0000-0003-0806-3164

Frija G., профессор (Париж, Франция)

ORCID: 0000-0003-0415-0586

Guglielmi G., MD, профессор (Фоджа, Италия)

ORCID: 0000-0002-4325-8330

Holodny A., д.м.н. (Нью-Йорк, США)

ORCID: 0000-0002-1159-2705

Лебедев Г.С., д.т.н., профессор (Москва, Россия)

ORCID: 0000-0002-4289-2102

Li H., MD, профессор (Пекин, КНР)

Mannelli L., MD (Нью-Йорк, США)

ORCID: 0000-0002-9102-4176

Матвеев И.А., д.т.н. (Москва, Россия)

ORCID: 0000-0003-2005-9467

Мацкеллишвили С.Т., д.м.н., профессор (Москва, Россия)

ORCID: 0000-0002-5670-167X

Митков В.В., д.м.н., профессор (Санкт-Петербург, Россия)

ORCID: 0000-0003-1959-9618

Морозов С.П., д.м.н., профессор (Москва, Россия)

ORCID: 0000-0001-6545-6170

Neri E., д.м.н. (Пиза, Италия)

ORCID: 0000-0001-7950-4559

Омельяновский В.В., д.м.н., профессор (Москва, Россия)

ORCID: 0000-0003-1581-0703

Омельянская О.В., (Москва, Россия)

ORCID: 0000-0002-0245-4431

Oudkerk M., профессор (Гронинген, Нидерланды)

ORCID: 0000-0003-2800-4110

Ros P.R., MD, PhD, профессор (Нью-Йорк, США)

ORCID: 0000-0003-3974-0797

Rovira A., профессор (Барселона, Испания)

ORCID: 0000-0002-2132-6750

Решетников Р.В., к.ф.-м.н., (Москва, Россия)

ORCID: 0000-0002-9661-0254

Румянцев П.О., д.м.н. (Москва, Россия)

ORCID: 0000-0002-7721-634X

Храмов А.Е., докт.ф.-м.н., профессор (Санкт-Петербург, Россия)

ORCID: 0000-0003-2787-2530

Аншелес А.А., д.м.н. (Москва, Россия)

ORCID: 0000-0002-2675-3276

Арутюнов Г.П., д.м.н. (Москва, Россия)

ORCID: 0000-0002-6645-2515

Белавский А.С., д.м.н., профессор (Москва, Россия)

ORCID: 0000-0001-6050-724X

Васильева Е.Ю., д.м.н., профессор (Москва, Россия)

ORCID: 0000-0003-4111-0874

Гехт А.Б., д.м.н., профессор (Москва, Россия)

ORCID: 0000-0002-1170-6127

Коблякова О.С., д.м.н., профессор (Москва, Россия)

ORCID: 0000-0001-9396-6063

Кремнева Е.И., к.м.н. (Москва, Россия)

ORCID: 0000-0003-3292-8789

Петриков С.С., д.м.н., профессор (Москва, Россия)

ORCID: 0000-0003-3292-8789

Проценко Д.Н., к.м.н. (Москва, Россия)

ORCID: 0000-0002-5166-3280

Хатьков И.Е., д.м.н., профессор (Москва, Россия)

ORCID: 0000-0002-4088-8118

Редакция не несет ответственности за содержание рекламных материалов. Точка зрения авторов может не совпадать с мнением редакции. К публикации принимаются только статьи, подготовленные в соответствии с правилами для авторов. Направляя статью в редакцию, авторы принимают условия договора публичной оферты. С правилами для авторов и договором публичной оферты можно ознакомиться на сайте: <https://journals.eco-vector.com/DD/>. Полное или частичное воспроизведение материалов, опубликованных в журнале, допускается только с письменного разрешения издателя — издательства «Эко-Вектор».



FOUNDERS

- Moscow Center for Diagnostics and Telemedicine
- Eco-Vector

PUBLISHER

Eco-Vector

Address: 3 liter A, 1H, Aptekarsky pereulok, 191186,
Saint Petersburg, Russian Federation
E-mail: info@eco-vector.com
WEB: <https://eco-vector.com>

ADVERTISE

Adv. department

Phone: +7 (968) 545 78 20
E-mail: adv2@eco-vector.com

EDITORIAL OFFICE

Executive editor

Elena A. Philippova
E-mail: ddjournal@eco-vector.com
Phone: +7 (965) 012 70 72

SUBSCRIPTION

For print version:
www.journals.eco-vector.com/

PUBLICATION ETHICS

Journal's ethic policies are based on:

- ICMJE
- COPE
- ORE
- CSE
- EASE

OPEN ACCESS

Immediate Open Access is mandatory for all published articles

INDEXATION

- SCOPUS
- Russian Science Citation Index
- Google Scholar
- Ulrich's International Periodicals Directory
- WorldCat

TYPESET

completed in Eco-Vector

Copyeditor: *A.A. Ridel*

Proofreader: *A.A. Ridel*

Layout editor: *Ph. Ignashchenko*

Cover: *E. Bugaenko*

ISSN 2712-8490 (Print)
ISSN 2712-8962 (Online)

Digital Diagnostics

Volume 5 | Issue 1 | 2024

QUARTERLY PEER-REVIEWED MEDICAL JOURNAL

EDITOR-IN-CHIEF

Valentin E. Sinitsyn, MD, Dr. Sci. (Med.), Professor (Moscow, Russia)
ORCID: 0000-0002-5649-2193

DEPUTY EDITOR-IN-CHIEF

Yuriy A. Vasilev, MD, Cand. Sci. (Med.) (Moscow, Russia)
ORCID: 0000-0002-0208-5218

SCIENTIFIC EDITOR

Tatiana P. Berezovskaya MD, Dr. Sci. (Med.), Professor (Obninsk, Russia)
ORCID: 0000-0002-3549-4499

RESPONSIBLE SECRETARY

Irina A. Vinogradova, Cand. Sci. (Eng.) (Moscow, Russia)
ORCID: 0000-0001-6465-4132

EDITORIAL BOARD

L. Berlin, Professor (Illinois, United States)
ORCID: 0000-0002-0717-0307
M.G. Belyaev, Cand. Sci. (Phys.-Math.), Assistant Professor (Moscow, Russia)
ORCID: 0000-0001-9906-6453
S. Bisdas, MD, PhD (London, United Kingdom)
ORCID: 0000-0001-9930-5549
D.A. Vazhenina, MD, Dr. Sci. (Med.), Associate Professor (Moscow, Russia)
ORCID: 0000-0002-6236-709X
V.A. Gomboleviskiy, MD, Dr. Sci. (Med.) (Moscow, Russia)
ORCID: 0000-0003-1816-1315
A.S. Domozhirova, MD, Dr. Sci. (Med.), Associate Professor (Moscow, Russia)
ORCID: 0000-0003-0806-3164
G. Frija, Professor (Paris, France)
ORCID: 0000-0003-0415-0586
G. Guglielmi, MD, Professor (Foggia, Italy)
ORCID: 0000-0002-4325-8330
A. Holodny, MD (New York, United States)
ORCID: 0000-0002-1159-2705
H. Li, MD, Professor (Beijing, China)
G.S. Lebedev, Dr. Sci. (Eng.), Professor (Moscow, Russia)
ORCID: 0000-0002-4289-2102
L. Mannelli, MD (New York, United States)
ORCID: 0000-0002-9102-4176
I.A. Matveev, Dr. Sci. (Tech.) (Moscow, Russia)
ORCID: 0000-0003-2005-9467
S.T. Matskeplishvili, MD, Dr. Sci. (Med.), Professor (Moscow, Russia)
ORCID: 0000-0002-5670-167X
V.V. Mit'kov, MD, Dr. Sci. (Med.), Professor (Saint Petersburg, Russia)
ORCID: 0000-0003-1959-9618
S.P. Morozov, MD, Dr. Sci. (Med.), Professor (Moscow, Russia)
ORCID: 0000-0001-6545-6170
E. Neri, MD, Associate Professor (Pisa, Italy)
ORCID: 0000-0001-7950-6559
V.V. Omel'yanovskiy, MD, Dr. Sci. (Med.), Professor (Moscow, Russia)
ORCID: 0000-0003-1581-0703
D.V. Omelyanskaya, (Moscow, Russia)
ORCID: 0000-0002-0245-4431
M. Oudkerk, Professor (Groningen, Netherlands)
ORCID: 0000-0003-2800-4110
P.R. Ros, MD, PhD, Professor (New York, United States)
ORCID: 0000-0003-3974-0797
A. Rovira, Professor (Barcelona, Spain)
ORCID: 0000-0002-2132-6750
R.V. Reshetnikov, Cand. Sci. (Phys.-Math.) (Moscow, Russia)
ORCID: 0000-0002-9661-0254
P.D. Rumyantsev, MD, Dr. Sci. (Med.) (Moscow, Russia)
ORCID: 0000-0002-7721-634X
A.E. Khamov, Dr. Sci. (Phys.-Math.), Professor (Saint Petersburg, Russia)
ORCID: 0000-0003-2787-2530

A.A. Ansheles, MD, Dr. Sci. (Med.) (Moscow, Russia)
ORCID: 0000-0002-2675-3276
G.P. Arutyunov, MD, Dr. Sci. (Med.) (Moscow, Russia)
ORCID: 0000-0002-6645-2515
A.S. Belevskiy, MD, Dr. Sci. (Med.), Professor (Moscow, Russia)
ORCID: 0000-0001-6050-724X
E.Y. Vasilieva, MD, Dr. Sci. (Med.), Professor (Moscow, Russia)
ORCID: 0000-0003-4111-0874
A.B. Gekht, MD, Dr. Sci. (Med.), Professor (Moscow, Russia)
ORCID: 0000-0002-1170-6127
O.S. Kobayakova, MD, Dr. Sci. (Med.), Professor (Moscow, Russia)
ORCID: 0000-0003-0098-1403
E.I. Kremneva, MD, Cand. Sci. (Med.) (Moscow, Russia)
ORCID: 0000-0001-9396-6063
S.S. Petrikov, MD, Dr. Sci. (Med.), Professor (Moscow, Russia)
ORCID: 0000-0003-3292-8789
D.N. Protsenko, MD, Cand. Sci. (Med.) (Moscow, Russia)
ORCID: 0000-0002-5166-3280
I.E. Khatkov, MD, Dr. Sci. (Med.), Professor (Moscow, Russia)
ORCID: 0000-0002-4088-8118

СОДЕРЖАНИЕ

ОРИГИНАЛЬНЫЕ ИССЛЕДОВАНИЯ

А.А. Арзамасцев, О.Л. Фабрикантов, Е.В. Кулагина, Н.А. Зенкова

Классификация снимков оптической когерентной томографии с использованием методов глубокого машинного обучения 5

М.Р. Хабазова, Е.Н. Пономарева, И.А. Лоскутов, Е.А. Каталевская, А.Ю. Сизов, Г.М. Габараев

Изучение возможностей программы искусственного интеллекта в диагностике заболеваний макулярной области. 17

А.В. Соловьёв, Ю.А. Васильев, В.Е. Сеницын, А.В. Петряйкин, А.В. Владзимирский, И.М. Шулькин, Д.Е. Шарова, Д.С. Семенов

Вклад систем искусственного интеллекта в улучшение выявления аневризм аорты по данным компьютерной томографии грудной клетки 29

В.А. Васильев, С.Н. Кондричина

Возможности использования виртуального симулятора «Vimedix 3.2» в процессе обучения по специальности «ультразвуковая диагностика» 41

А.А. Арзамасцев, О.Л. Фабрикантов, Н.А. Зенкова, С.В. Беликов

Применение технологии машинного обучения для прогнозирования оптической силы интраокулярных линз: генерализация диагностических данных 53

Е.К. Цыренжапова, О.И. Розанова, Т.Н. Юрьева, А.А. Иванов, И.С. Розанов

Технологии машинного обучения и искусственной нейронной сети в классификации посткератотомической деформации роговицы 64

А.Д. Чупров, И.П. Болодурина, А.О. Лосяцкий, А.Ю. Жигалов

Организация диспансерного наблюдения пациентов с патологией макулярной области сетчатки с использованием систем искусственного интеллекта 75

СИСТЕМАТИЧЕСКИЕ ОБЗОРЫ

Ю.А. Трусов, В.С. Чупахина, А.С. Нуркаева, Н.А. Яковенко, И.В. Абленина, Р.Ф. Латыпова, А.П. Питке,

А.А. Язовских, А.С. Иванов, Д.С. Богатырева, У.А. Попова, А.Ф. Юзлекбаев

Применение искусственного интеллекта в диагностике кальцификации артерий 85

НАУЧНЫЕ ОБЗОРЫ

Ю.А. Васильев, А.В. Владзимирский, К.М. Арзамасов, Д.У. Шихмурадов,

А.В. Панкратов, И.В. Улянов, Н.Б. Нечаев

Перспективы применения компьютерного зрения для выявления камней в мочевыделительной системе и новообразований печени и почек на изображениях компьютерной томографии органов брюшной полости и забрюшинного пространства. 101

А.В. Баева

Эпистемический статус искусственного интеллекта в медицинских практиках: этические вызовы 120

CONTENTS

ORIGINAL STUDY ARTICLES

<i>Alexander A. Arzamastsev, Oleg L. Fabrikantov, Elena V. Kulagina, Natalia A. Zenkova</i> Classification of optical coherence tomography images using deep machine-learning methods.	5
<i>Margarita R. Khabazova, Elena N. Ponomareva, Igor A. Loskutov, Evgenia A. Katalevskaya, Aleksandr Yu. Sizov, Georgy M. Gabaraev</i> Exploring the possibilities of an artificial intelligence program in the diagnosis of macular diseases	17
<i>Alexander V. Solovlev, Yuriy A. Vasilev, Valentin E. Sinitsyn, Alexey V. Petraikin, Anton V. Vladzimirskyy, Igor M. Shulkin, Daria E. Sharova, Dmitry S. Semenov</i> Improving aortic aneurysm detection with artificial intelligence based on chest computed tomography data	29
<i>Valeri A. Vasilev, Svetlana N. Kondrichina</i> Possibilities for using the Vimedix 3.2 virtual simulator to train ultrasound specialists.	41
<i>Alexander A. Arzamastsev, Oleg L. Fabrikantov, Natalia A. Zenkova, Sergey V. Belikov</i> Machine-learning technology for predicting intraocular lens power: Diagnostic data generalization	53
<i>Ekaterina K. Tsyrenzhapova, Olga I. Rozanova, Tatiana N. Iureva, Andrey A. Ivanov, Ivan S. Rozanov</i> Machine-learning and artificial neural network technologies in the classification of postkeratotomy corneal deformity	64
<i>Aleksandr D. Chuprov, Irina P. Bolodurina, Aleksandr O. Lositskiy, Artur Yu. Zhigalov</i> Organizing follow-up care for patients with macular retinal pathologies using artificial intelligence systems.	75

SYSTEMATIC REVIEWS

<i>Yuri A. Trusov, Victoria S. Chupakhina, Adilya S. Nurkaeva, Natalia A. Yakovenko, Irina V. Ablenina, Roksana F. Latypova, Aleksandra P. Pitke, Anastasiya A. Yazovskikh, Artem S. Ivanov, Darya S. Bogatyreva, Ulyana A. Popova, Azat F. Yuzlekbaev</i> Use of artificial intelligence in the diagnosis of arterial calcification	85
---	----

REVIEWS

<i>Yuriy A. Vasilev, Anton V. Vladzimirskyy, Kirill M. Arzamasov, David U. Shikhmuradov, Andrey V. Pankratov, Iliya V. Ulyanov, Nikolay B. Nechaev</i> Prospects of using computer vision technology to detect urinary stones and liver and kidney neoplasms on computed tomography images of the abdomen and retroperitoneal space	101
<i>Angelina V. Baeva</i> Epistemic status of artificial intelligence in medical practice: Ethical challenges	120

DOI: <https://doi.org/10.17816/DD623801>

Классификация снимков оптической когерентной томографии с использованием методов глубокого машинного обучения

А.А. Арзамасцев^{1,2}, О.Л. Фабрикантов², Е.В. Кулагина², Н.А. Зенкова³¹ Воронежский государственный университет, Воронеж, Россия;² Национальный медицинский исследовательский центр «Межотраслевой научно-технический комплекс “Микрохирургия глаза” имени академика С.Н. Фёдорова», Тамбов, Россия;³ Тамбовский государственный университет имени Г.Р. Державина, Тамбов, Россия

АННОТАЦИЯ

Обоснование. Оптическая когерентная томография — современный высокотехнологичный и информативный метод выявления патологии сетчатки глаза и преретинальных слоёв стекловидного тела. Однако описание и интерпретация результатов исследования требуют высокой квалификации и специальной подготовки врача-офтальмолога, а также значительных временных затрат врача и пациента. Вместе с тем использование математических моделей на основе аппарата искусственных нейронных сетей в настоящее время позволяет автоматизировать многие процессы, связанные с обработкой изображений. Именно поэтому актуально решение задач, связанных с автоматизацией процесса классификации снимков оптической когерентной томографии на основе глубокого обучения моделей искусственных нейронных сетей.

Цель — разработать архитектуры математических (компьютерных) моделей на основе глубокого обучения свёрточных нейронных сетей, предназначенных для классификации снимков оптической когерентной томографии сетчатки глаза; сравнить результаты вычислительных экспериментов, проведённых с использованием средств Python в Google Colaboratory при одно- и многомодельном подходе, и выполнить оценки точности классификации; сделать выводы об оптимальной архитектуре моделей искусственных нейронных сетей и значениях используемых гиперпараметров.

Материалы и методы. Исходный датасет, представляющий собой обезличенные снимки оптической когерентной томографии реальных пациентов, включал более 2000 изображений, полученных непосредственно с прибора в разрешении 1920×969×24 BPP. Количество классов изображений — 12. Для создания обучающего и валидационного наборов данных осуществляли «вырезание» предметной области 1100×550×24 BPP. Изучали различные подходы: возможность использования предобученных свёрточных нейронных сетей с переносом обучения, методики изменения размера и аугментации изображений, а также различные сочетания гиперпараметров моделей искусственных нейронных сетей. При компиляции модели использовали следующие параметры: оптимизатор Adam, функцию потерь categorical_crossentropy, метрику accuracy. Все технологические процессы с изображениями и моделями искусственных нейронных сетей проводили с использованием средств языка Python в Google Colaboratory.

Результаты. Предложены одно- и многомодельный принципы классификации изображений оптической когерентной томографии сетчатки глаза. Вычислительные эксперименты по автоматизированной классификации таких изображений, полученных с томографа DRI OCT Triton, с использованием различных архитектур моделей искусственных нейронных сетей показали точность при обучении и валидации 98–100%, и на дополнительном тесте — 85%, что является удовлетворительным результатом. Выбрана оптимальная архитектура модели искусственной нейронной сети — 6-слойная свёрточная сеть, — и определены значения её гиперпараметров.

Заключение. Результаты глубокого обучения моделей свёрточных нейронных сетей с различной архитектурой, их валидации и тестирования показали удовлетворительную точность классификации снимков оптической когерентной томографии сетчатки глаза. Данные разработки могут быть использованы в системах поддержки принятия решений в области офтальмологии.

Ключевые слова: искусственный интеллект; медицинские данные; датасет; машинное обучение; свёрточные нейронные сети; оптическая когерентная томография.

Как цитировать:

Арзамасцев А.А., Фабрикантов О.Л., Кулагина Е.В., Зенкова Н.А. Классификация снимков оптической когерентной томографии с использованием методов глубокого машинного обучения // Digital Diagnostics. 2024. Т. 5, № 1. С. 5–16. DOI: <https://doi.org/10.17816/DD623801>

Рукопись получена: 24.11.2023

Рукопись одобрена: 12.02.2024

Опубликована online: 11.03.2024

DOI: <https://doi.org/10.17816/DD623801>

Classification of optical coherence tomography images using deep machine-learning methods

Alexander A. Arzamastsev^{1, 2}, Oleg L. Fabrikantov², Elena V. Kulagina², Natalia A. Zenkova³

¹ Voronezh State University, Voronezh, Russia;

² The S. Fyodorov Eye Microsurgery Federal State Institution, Tambov, Russia;

³ Derzhavin Tambov State University, Tambov, Russia

ABSTRACT

BACKGROUND: Optical coherence tomography is a modern high-tech, insightful approach to detecting pathologies of the retina and preretinal layers of the vitreous body. However, the description and interpretation of study findings require advanced qualifications and special training of ophthalmologists and are highly time-consuming for both the doctor and the patient. Moreover, mathematical models based on artificial neural networks now allow for the automation of many image processing tasks. Therefore, addressing the issues of automated classification of optical coherence tomography images using deep learning artificial neural network models is crucial.

AIM: To develop architectures of mathematical (computer) models based on deep learning of convolutional neural networks for the classification of retinal optical coherence tomography images; to compare the results of computational experiments conducted using Python tools in Google Colaboratory with single-model and multimodel approaches, and evaluate classification accuracy; and to determine the optimal architecture of models based on artificial neural networks, as well as the values of the hyperparameters used.

MATERIALS AND METHODS: The original dataset included >2,000 anonymized optical coherence tomography images of real patients, obtained directly from the device with a resolution of 1,920×969×24 BPP. The number of image classes was 12. To create the training and validation datasets, a subject area of 1,100×550×24 BPP was “cut out”. Various approaches were studied: the possibility of using pretrained convolutional neural networks with transfer learning, techniques for resizing and augmenting images, and various combinations of the hyperparameters of models based on artificial neural networks. When compiling a model, the following parameters were used: Adam optimizer, categorical_crossentropy loss function, and accuracy. All technological operations involving images and models based on artificial neural networks were performed using Python language tools in Google Colaboratory.

RESULTS: Single-model and multimodel approaches to the classification of retinal optical coherence tomography images were developed. Computational experiments on the automated classification of such images obtained from a DRI OCT Triton tomograph using various architectures of models based on artificial neural networks showed an accuracy of 98–100% during training and validation, and 85% during an additional test, which is a satisfactory result. The optimal architecture of the model based on an artificial neural network, a six-layer convolutional network, was selected, and the values of its hyperparameters were determined.

CONCLUSION: Deep training of convolutional neural network models with various architectures, as well as their validation and testing, resulted in satisfactory classification accuracy of retinal optical coherence tomography images. These findings can be used in decision support systems in ophthalmology.

Keywords: artificial intelligence; medical data; dataset; machine learning; convolutional neural networks; optical coherence tomography.

To cite this article:

Arzamastsev AA, Fabrikantov OL, Kulagina EV, Zenkova NA. Classification of optical coherence tomography images using deep machine-learning methods. *Digital Diagnostics*. 2024;5(1):5–16. DOI: <https://doi.org/10.17816/DD623801>

Submitted: 24.11.2023

Accepted: 12.02.2024

Published online: 11.03.2024

DOI: <https://doi.org/10.17816/DD623801>

利用深度机器学习技术对光学相干断层扫描图片进行分类

Alexander A. Arzamastsev^{1,2}, Oleg L. Fabrikantov², Elena V. Kulagina², Natalia A. Zenkova³¹ Voronezh State University, Voronezh, Russia;² The S. Fyodorov Eye Microsurgery Federal State Institution, Tambov, Russia;³ Derzhavin Tambov State University, Tambov, Russia

摘要

论证。光学相干断层扫描是一种现代高科技和信息丰富的方法，用于检测视网膜和玻璃体视网膜前层的病理。然而，对研究结果的描述和解释需要眼科医生的高技能和专业培训，还需要医生和病人花费大量时间。与此同时，如今使用基于人工神经网络设备的数学模型可以实现许多图片处理过程的自动化。因此，在人工神经网络模型深度学习的基础上解决光学相干断层扫描图片分类过程的自动化问题具有现实意义。

目的。本研究的目的是开发基于卷积神经网络深度学习的数学（计算机）模型结构，此类网络设计被用于视网膜光学相干断层扫描的图像分类；使用Google Colaboratory的Python工具，比较单一模型和多模型方法的计算实验结果，并评估分类准确性；就人工神经网络模型的最佳架构和所使用的超参数值得出结论。

材料与方法。原始数据集是真正患者的匿名光学相干断层扫描图像，其中包括2000多张图像。图像直接从设备中获取，分辨率为 $1920 \times 969 \times 24$ BPP。图像类别数量为12个。为了创建训练和验证数据集，对 $1100 \times 550 \times 24$ BPP主题区域进行了“切割”。研究了不同的方法：使用带学习转移的预训练卷积神经网络的可能性、图像缩放和增强技术，以及人工神经网络模型超参数的不同组合。在编制模型时，使用了以下参数：Adam优化器、categorical_crossentropy损失函数、accuracy指标。所有图像和人工神经网络模型的技术处理都是通过Google Colaboratory的Python语言工具进行的。

结果。提出了视网膜光学相干断层扫描图片分类的单模型和多模型原理。使用不同的人工神经网络模型架构对来自DRI OCT Triton断层扫描仪的此类图像进行自动分类的计算实验表明了，训练和验证期间的准确率为98%–100%，额外测试的准确率为85%。这是一个令人满意的结果。人工神经网络模型的最佳架构是6层卷积网络，并确定了其超参数值。

结论。对不同结构的卷积神经网络模型进行深度学习、验证和测试的结果表明，视网膜光学相干断层扫描图片分类的准确度令人满意。这些研制成果可被用于眼科领域的决策支持系统。

关键词：人工智能；医学数据；数据集；机器学习；卷积神经网络；光学相干断层扫描。

引用本文：

Arzamastsev AA, Fabrikantov OL, Kulagina EV, Zenkova NA. 利用深度机器学习技术对光学相干断层扫描图片进行分类. *Digital Diagnostics*. 2024;5(1):5–16. DOI: <https://doi.org/10.17816/DD623801>

收到: 24.11.2023

接受: 12.02.2024

发布日期: 11.03.2024

ОБОСНОВАНИЕ

Оптическая когерентная томография (ОКТ) — современный высокотехнологичный и информативный метод выявления патологии сетчатки глаза и преретинальных слоёв стекловидного тела [1]. Однако описание и интерпретация результатов исследования требуют высокой квалификации и специальной подготовки врача, а также значительных временных затрат офтальмолога и пациента. По этой причине решение задач, связанных с автоматизацией процесса классификации снимков ОКТ, является актуальным.

Вместе с тем в настоящее время наблюдается быстрое развитие компьютерного инструментария и технологий, позволяющих создавать системы искусственного интеллекта на основе нейронных сетей различной архитектуры, как медицинских [2, 3], так и общего назначения [4–6]. Современные офтальмологические центры за последние десятилетия создали хранилища данных о пациентах, включающие десятки и сотни тысяч снимков ОКТ, что открывает путь к поиску обобщённых зависимостей и связей между отдельными параметрами и построению принципиально новых подходов для идентификации, классификации, расчётов и предсказаний на основе научного подхода, ядром которого практически всегда является математическая модель.

В одной из своих работ мы уже описали компьютерные методы анализа стекловидного тела, выделения и аппроксимации границы сетчатки, определения кривизны границы, расчётов средней толщины сетчатки и др., выполненных в том числе и с использованием искусственных нейронных сетей (ИНС) [7]. В данной статье, являющейся логическим продолжением этой работы, представлены результаты, полученные при классификации снимков ОКТ с использованием свёрточных нейронных сетей (СНС) с использованием одно- и многомодельного подходов.

Необходимо отметить, что решению близких проблем посвящено несколько опубликованных работ. Так, Ю.А. Васильев и соавт. [8] разработали общую методологию тестирования и мониторинга программного обеспечения на основе технологий искусственного интеллекта для медицинской диагностики. Методология направлена на повышение качества данного программного обеспечения и его внедрение в практическое здравоохранение. Она состоит из семи этапов: самотестирование, функциональное тестирование, калибровочное тестирование, технологический мониторинг, клинический мониторинг, обратная связь и доработка. Отличительной особенностью методологии является цикличность этапов тестирования, мониторинга и доработки программного обеспечения, приводящая к постоянному повышению его качества, а также наличие подробных требований к результатам его работы и участие врачей в его оценке. Методология позволяет разработчикам программного обеспечения

достичь высоких результатов и продемонстрировать достижения в различных направлениях, а пользователям — сделать осознанный и уверенный выбор среди программ, прошедших независимую и всестороннюю проверку качества.

Целью статьи Е.А. Каталевской и соавт. [9] являлась разработка алгоритмов сегментации визуальных признаков диабетической ретинопатии и диабетического макулярного отёка на цифровых фотографиях глазного дна, сделанных с помощью фундус-камеры. Для сегментации были выбраны признаки, включённые в Международную классификацию: микроаневризмы, твёрдые экссудаты, мягкие экссудаты, интравитреальные геморрагии, неоваскуляризация сетчатки и диска зрительного нерва, преретинальные геморрагии, эпиретинальный фиброз, лазерные коагуляты. Реализацию нейронных сетей и процесс их обучения осуществляли с помощью фреймворка глубокого обучения TensorFlow (Google Brain, США). Объём обучающей базы данных составил 1200 фотографий, в то время как для валидации использовали 310 фотографий глазного дна. Точность определения указанных признаков по обученной модели составила от 86% до 96%.

В работе Т. Керр и соавт. [10] описана система домашнего мониторинга возрастной макулярной дегенерации. СНС здесь использовали для сегментации всей сетчатки, а также отслоений пигментного эпителия. Весь датасет, включающий 711 изображений, был разделён на части: обучение/валидация/тест в пропорции 60%:20%:20%. Показано, что подход на основе СНС позволяет сегментировать сетчатку достаточно точно.

Целью работы С.Н. Сахнова и соавт. [11] была разработка модели скрининга катаракты на основе открытого набора данных, а также её валидация на клинических данных. При этом открытый набор данных состоял из 9668 изображений, полученных с помощью камеры смартфона, из которых 4514 изображений относились к классу «катаракта», а 5154 — к здоровым глазам. Набор для внешней валидации содержал 51 изображение с катарактой и нормой. Для создания модели машинного обучения использовали СНС. Значение точности классификации данных составило 97% для внутреннего валидационного набора, и 75% — для внешнего. Прогностическое значение, по мнению авторов, было низким, и был сделан вывод о том, что необходимо произвести донастройку модели и обеспечить необходимые уровни метрик эффективности.

В работе С.В. Шухаева и соавт. [12] использовали предобученные сети ResNet-18, ResNet-50, VGG16, VGG19 и GoogleNet для решения задачи применимости СНС для автоматического определения дистрофии Фукса. Была произведена выборка случайных ($n=700$) биомикроскопических снимков роговицы, полученных при помощи эндотелиального микроскопа Tomey EM-3000 (Tomey Corporation, Япония). На первом этапе выполнялось разделение снимков на 2 группы. Первая группа включала снимки с наличием дистрофии Фукса, вторая — норму

или другую патологию. Снимки плотности эндотелиальных клеток были разделены на три категории: тренировочный, валидационный и тестовый наборы данных. В результате апробации нейронной сети на тестовой выборке были получены следующие значения F-метрики для различных архитектур СНС: ResNet-18 — 0,985; ResNet-50 — 1,000; VGG16 — 0,940; VGG19 — 0,990; GoogleNet — 0,987. ResNet-50 показала лучший результат на данных ImageNet с замороженными слоями, оптимизатором Adam и кросс-энтропией в качестве функции потерь.

Таким образом, краткий анализ указанных работ позволяет сделать выводы о перспективности использования ИНС-моделей на основе СНС для решения задачи классификации изображений ОКТ сетчатки глаза.

ЦЕЛЬ

Разработать архитектуры математических (компьютерных) моделей на основе глубокого обучения СНС для классификации снимков ОКТ с использованием библиотек Python Keras и Tensorflow в Google Colaboratory. Сравнить результаты вычислительных экспериментов по классификации снимков ОКТ, полученных при одно- и многомодельном подходе и выполнить оценки точности такой классификации. Сделать выводы об оптимальной с точки зрения точности классификации архитектуре ИНС-моделей и значениях используемых гиперпараметров.

МАТЕРИАЛЫ И МЕТОДЫ

Первоначальный датасет представлял собой обезличенные снимки ОКТ реальных пациентов и включал 1004 изображения, полученных непосредственно с томографа DRI OCT Triton (Topcon Corporation, Япония) в разрешении 1920×969×24 BPP в виде файлов формата JPG. В соответствии с целями классификации весь датасет был разделён опытными врачами-офтальмологами на 12 классов:

- 1 — норма;
- 2 — кистозный макулярный отёк;
- 3 — отслойка нейроэпителия;
- 4 — отслойка пигментного эпителия;
- 5 — твёрдые экссудаты;
- 6 — эпиретинальный фиброз;
- 7 — витреомакулярная адгезия;
- 8 — задняя отслойка стекловидного тела;
- 9 — сквозной макулярный разрыв + эпиретинальный фиброз;
- 10 — твёрдые экссудаты + кистозный макулярный отёк;
- 11 — друзы пигментного эпителия;
- 12 — ламеллярный разрыв + эпиретинальный фиброз.

Количество изображений каждого класса соответствовало частоте встречаемости соответствующей патологии у пациентов. В последующих вычислительных

экспериментах датасет был дополнен новыми снимками ОКТ, так что их общее число составило более 2000 изображений. Для создания обучающего, валидационного и тестового наборов данных осуществляли «вырезание» из всего снимка предметной области 1100×550×24 BPP. Весь датасет при проведении вычислительных экспериментов, как правило, был разделён на три части: обучение/валидация/тест, в пропорции 70%:20%:10%.

Были использованы также следующие технологические приёмы:

- изменение размера изображения (rescale) с использованием фильтров NEAREST, BILINEAR, BICUBIC, LANCZOS;
- аугментация данных (augmentation) с использованием различных опций — поворот изображения на заданный угол, смещение изображения по направлениям X и Y, горизонтальный и вертикальный повороты, изменение яркости канала изображения.

Отметим, что при использовании фильтров наилучшие результаты в нашем случае показал простейший NEAREST, учитывающий параметры ближайшего пикселя. Более сложные фильтры, осуществляющие аппроксимацию области различными методами, показали худшие результаты. По всей видимости, это происходило по причине того, что при сглаживании терялись мелкие детали изображений, важные для классификации.

При компиляции модели использовали следующие параметры:

- оптимизатор Adam — один из самых эффективных алгоритмов оптимизации;
- функция потерь categorical_crossentropy — категориальная перекрёстная энтропия;
- метрика ассигасу — доля правильных ответов алгоритма.

Необходимо отметить, что метрика ассигасу обычно используется для решения задачи классификации, если группы являются сбалансированными по количеству снимков. В нашем случае из-за малого числа снимков в обучающей и тестовой выборках было решено сделать общую среднюю оценку.

Все технологические процессы с моделями проводили с использованием средств языка Python в Google Colaboratory.

РЕЗУЛЬТАТЫ

Предварительные вычислительные эксперименты

В предварительных вычислительных экспериментах оценивали эффективность для классификации снимков ОКТ различных подходов (таких как возможность использования предобученных сетей и переноса обучения), методик изменения размера и аугментации изображений, а также сочетаний гиперпараметров ИНС-моделей (число свёрточных и полносвязных слоёв, размер пакета и т.д.).

Для предобученных нейронных сетей на основе MobileNetV2 и MobileNetV3 на обучающей выборке достигнута точность 95–98%, на валидации — 61–80%, на тесте — 41–59%. При этом использовали инструмент для масштабирования изображения до размера 224×224 пикселей, чтобы добиться соответствия с MobileNet.

Выполнено также сравнение обучаемости на указанном датасете различных предобученных нейронных сетей с переносом обучения. Получены следующие результаты их валидации: для MobileNetV2 — 80%, для ResNet101V2 — 81%, для InceptionResNetV2 — 79%, для NASNetLarge — 80%.

Для многослойных СНС, имеющих традиционную архитектуру (несколько свёрточных слоёв Conv2D, в каждом из которых имеется и функция подвыборки MaxPooling2D, преобразование массивов в одномерный тензор Flatten и несколько полносвязных слоёв Dense), на обучающей выборке достигается точность в 70–100% при разумном выборе количества эпох. Однако на валидационной выборке этот показатель значительно ниже и имеет больший разброс (35–94%). В двух случаях точность валидации оказалась выше точности, показанной на обучении, что можно связать со значительной неоднородностью данных обучающей и валидационной выборок. На тестах точность оказалась ещё ниже и составила всего 27–59%, что, конечно, не могло быть признано удовлетворительным результатом.

В результате предварительных экспериментов были сделаны следующие выводы:

- обучающая выборка является несбалансированной и неоднородной и нуждается в коррекции и дополнении новыми снимками;

- хотя модели с переносом обучения показали несколько лучшие результаты классификации, эти результаты всё ещё недостаточны для их использования в офтальмологической практике, а за счёт «заморозки» первых скрытых слоёв остаётся не очень много возможностей для их усовершенствования;
- для достижения приемлемой точности классификации требуется оптимизация гиперпараметров и, возможно, самого подхода к классификации.

Вычислительные эксперименты: одномодельный подход

С учётом результатов, полученных в ходе предварительных экспериментов, датасет был дополнен новыми снимками ОКТ, так что общее число изображений стало более 2000. В ходе экспериментов тестировали различные архитектуры многослойных последовательных (sequential) СНС: несколько свёрточных слоёв Conv2D, на выходе каждого из которых имелся слой подвыборки MaxPooling2D, а также слой, осуществляющий преобразование в одномерный тензор Flatten, и два полносвязных слоя Dense, последний из которых имел передаточную функцию нейронов softmax, удобную для решения задачи классификации.

Для разрешения нормализованного снимка 512×512 пикселей, к которому приводили все изображения датасета с использованием инструмента rescale, предельное число свёрточных слоёв составляет 7. Тестировали структуры СНС с числом таких слоёв от 2 до 7 (табл. 1), одновременно подбирая размер и количество фильтров в слоях. Для всех вычислительных экспериментов проводили обучение (как правило, с числом эпох epochs=15,

Таблица 1. Сравнение различных последовательных моделей искусственных нейронных сетей

Число свёрточных слоёв	Число оптимизируемых параметров	Точность обучения, %	Точность валидации, %	Точность на дополнительном тесте, %	Примечание
2	31 844 921	13	0	0	ИНС-модель плохо обучается
3	13 401 045	97	100	55	Число эпох обучения ИНС-модели: больше 15. Количество фильтров в слоях СНС: 3/8/16
3	15 215 889	100	100	62	Число эпох обучения ИНС-модели: 9. Количество фильтров в слоях СНС: 4/8/16
3	13 401 933	100	100	64	Число эпох обучения ИНС-модели: 12. Количество фильтров в слоях СНС: 5/8/16
4	6 929 729	100	100	65	Число эпох обучения ИНС-модели: 12
5	1 430 977	100	100	70	Число эпох обучения ИНС-модели: 9
6	556 673	100	100	85	Число эпох обучения ИНС-модели: 15
7	132 801	100	89	74	Число эпох обучения ИНС-модели: больше 15
8	—	—	—	—	8 слоёв СНС невозможно использовать для принятого размера изображений

Примечание. ИНС — искусственная нейронная сеть; СНС — свёрточная нейронная сеть.

размером пакета `BATCH_SIZE=50` и параметрами компиляции `optimizer='adam'`, `loss='categorical_crossentropy'`, `metrics=['accuracy']`), а также валидацию и дополнительное тестирование на изображениях, ранее не включённых в датасет.

Практически для всех ИНС-моделей, за исключением двухслойной, достигнута приемлемая точность обучения и валидации (см. табл. 1). Однако если сравнить точность прохождения ими дополнительного теста, то она сначала возрастает по мере увеличения числа свёрточных слоёв, достигая максимального значения 85% в шестислойной модели, а затем убывает для семислойной. Необходимо отметить, что в настоящее время приведённые здесь модели позиционируются исключительно как система поддержки принятия решения врача-офтальмолога. Учитывая, что датасет содержит лишь ограниченное число снимков различных патологий, уровень 85% был принят нами как достаточный и соответствующий классификации снимков врачом-офтальмологом с небольшим опытом работы. Сделан вывод о том,

что существует оптимальное, с точки зрения точности, число слоёв, которое в данном случае равно 6. Однако это значение может быть в дальнейшем изменено по мере накопления новых данных в датасете и переобучения моделей.

На рис. 1 показаны процессы обучения и валидации ИНС-моделей с числом свёрточных слоёв от 4 до 7. При использовании 4 и 5 свёрточных слоёв процесс обучения завершается после 9 эпох, достигая точности на обучении и валидации 100%. При этом точность прохождения дополнительного теста составляет всего 65–70% (см. табл. 1). В случае использования модели с 6 свёрточными слоями процесс обучения занимает более длительное время — 15 эпох, также достигая точности на обучении и валидации 100%. Однако точность прохождения дополнительного теста возрастает до 85%, что сочтено нами за удовлетворительный результат. При дальнейшем увеличении числа свёрточных слоёв до 7 процесс обучения и валидации ИНС-модели занимает более 15 эпох, при этом точность обучения составляет 100%, а точность




Рис. 1. Обучение и валидация моделей свёрточных нейронных сетей: *a* — четыре свёрточных слоя; *b* — пять свёрточных слоёв; *c* — шесть свёрточных слоёв; *d* — семь свёрточных слоёв.

```
[ ] model = tf.keras.models.Sequential([
    tf.keras.layers.Conv2D(4, (9,9), activation='relu', input_shape=(IMG_SHAPE, IMG_SHAPE, 3)),
    tf.keras.layers.MaxPooling2D(2, 2),

    tf.keras.layers.Conv2D(8, (5, 5), activation='relu'),
    tf.keras.layers.MaxPooling2D(2, 2),

    tf.keras.layers.Conv2D(16, (3, 3), activation='relu'),
    tf.keras.layers.MaxPooling2D(2, 2),

    tf.keras.layers.Conv2D(32, (3, 3), activation='relu'),
    tf.keras.layers.MaxPooling2D(2, 2),

    tf.keras.layers.Conv2D(32, (3, 3), activation='relu'),
    tf.keras.layers.MaxPooling2D(2, 2),

    tf.keras.layers.Conv2D(64, (3, 3), activation='relu'),
    tf.keras.layers.MaxPooling2D(2, 2),

    tf.keras.layers.Flatten(),
    tf.keras.layers.Dense(225, activation='relu'),
    tf.keras.layers.Dense(12, activation='softmax')
])
```

Рис. 2. Архитектура и параметры модели искусственной нейронной сети с шестью свёрточными слоями. Первая цифра в Conv2D — число используемых фильтров в слое свёртки, две следующие цифры — размер фильтра в пикселях. Активационные функции нейронов сети — relu, в выходном слое классификации — softmax. Первая цифра в полносвязном слое Dense — число нейронов.

валидации и прохождения теста снижается до 89% и 74% соответственно (см. рис. 1 и табл. 1).

На рис. 2 показана архитектура оптимальной ИНС-модели с точки зрения точности классификации снимков ОКТ сетчатки глаза. Она включает 6 свёрточных слоёв Conv2D с подвыборкой MaxPooling2D, слой Flatten и два полносвязных слоя Dense, выполняющих роль классификатора, последний из которых имеет передаточную функцию нейронов softmax.

Объяснением более низкой (по сравнению с обучением и валидацией) точности классификации, полученной на тестах, является следующее обстоятельство. Для обучения моделей используются относительно небольшие датасеты, содержащие порядка 2000 снимков, которые, по всей видимости, не содержат полный набор графических деталей, характерных для той или иной патологии. Если в тестовой выборке встречаются такие детали, то классификация может быть неверной даже при условии 100%-й точности, полученной при валидации ИНС-модели.

Предварительные вычислительные эксперименты: многомодельный подход

Следуя общей логике исследования, а также учитывая необходимость повышения точности прохождения дополнительного теста, О.Л. Фабрикантовым и Е.В. Кулагиной была предложена последовательная схема, в общих чертах имитирующая процесс идентификации изображения ОКТ сетчатки глаза врачом-офтальмологом. На её основе был построен компьютерный алгоритм (см. рис. 2).

Данный алгоритм предполагает многомодельный последовательный принцип реализации (рис. 3).

На первом этапе производится предварительная обработка снимков (блоки 1–3). В блоке 4 используется ИНС-модель 1, которая осуществляет предварительную классификацию — отличает норму от какой-либо патологии. Результат такой классификации сохраняется (S1). Такая модель должна быть обучена и подвергнута валидации на специальном датасете 1, содержащем лишь два соответствующих класса изображений. Если патология не обнаружена (блок 5), то осуществляем переход к четвёртому этапу — анализу стекловидного тела, минуя все промежуточные этапы. Аналогично в блоке 6: используем ИНС-модель 2, обученную на специальном датасете 2 и позволяющую выявить, имеется ли макулярный разрыв, или он отсутствует. Результат сохраняется (S2). Если макулярный разрыв есть (блок 7), то в блоке 8 на основе ИНС-модели 3, также обученной на специальном датасете 3, определяется, имеет ли место сквозной или ламеллярный макулярный разрыв, после чего сохраняются результаты (S3), и осуществляется переход ко второму этапу.

Если макулярного разрыва нет (блок 7), то осуществляется переход к блоку 9, в котором с помощью ИНС-модели 4, обученной на специальном датасете 4, выявляется один из трёх вариантов — кистозный макулярный отёк, диффузный макулярный отёк или их отсутствие. Результат сохраняется (S4), и осуществляется переход ко второму этапу.

На втором этапе с помощью ИНС-модели 5 (блок 10), обученной на специальном датасете 5, выявляется один из трёх вариантов — отслойка нейрорепителлия, отслойка пигментного эпителия или отсутствие указанных




Рис. 3. Блок-схема многомодельного алгоритма идентификации снимков оптической когерентной томографии. ИНС — искусственная нейронная сеть; ОКТ — оптическая когерентная томография.

вариантов, после чего осуществляется сохранение результата (S5) и переход к третьему этапу анализа и классификации снимков ОКТ.

На третьем этапе происходит последовательное использование ИНС-моделей 6, 7 и 8.

- ИНС-модель 6 (блок 11) обучена на специальном датасете 6 распознаванию наличия или отсутствия эпиретинального фиброза.
- ИНС-модель 7 (блок 12) обучена на специальном датасете 7 распознаванию наличия или отсутствия друзов.
- ИНС-модель 8 (блок 13) обучена на специальном датасете 8 распознаванию наличия или отсутствия экссудатов.

В блоках 11–13 осуществляется также и сохранение соответствующих результатов (S6, S7, S8), после чего выполняется переход к четвертому этапу.

На четвертом этапе происходит использование ИНС-модели 9 (блок 14), обученной на специальном датасете 9 распознаванию нормы, задней отслойки стекловидного тела, витреомакулярной адгезии и витреомакулярной тракции. Результаты сохраняются (S9). В блоках 15 и 16 происходит формирование общего списка патологий на основании ранее сохранённых S1–S9 и вывод отчёта с описанием карты ОКТ в файл.

ОБСУЖДЕНИЕ

В описанном подходе для классификации патологии по снимкам ОКТ используются 9 различных ИНС-моделей, каждая из которых обучена на своём уникальном датасете (1–9). Следует отметить, что на завершающем этапе анализа стекловидного тела вместо ИНС-модели 9 может

быть использован алгоритм, описанный нами ранее [7]. Он включает:

- вертикальное сканирование снимка и определение координат X и Y границ стекловидного тела;
- сглаживание координат Y по методу скользящего среднего с базой, соизмеримой с минимальными деталями изображения (в нашем случае — 10 пикселей), аппроксимацией границы стекловидного тела сплайном или параболой соответствующего порядка;
- расчёт максимальной кривизны границы и соответствующих расстояний для идентификации задней отслойки стекловидного тела, витреомакулярной адгезии и витреомакулярной тракции.

В настоящее время осуществляется тестирование многомодельного алгоритма (см. рис. 3) одновременно с увеличением количества снимков ОКТ в датасетах и оптимизацией гиперпараметров ИНС-моделей. Предварительные вычислительные эксперименты, проведённые для нескольких этапов этого алгоритма, показали, что здесь удаётся добиться точности в 98–100% на обучении и валидации, при этом точность прохождения дополнительного теста возрастает по сравнению с одномодельным подходом за счёт уменьшения числа классифицируемых на каждом этапе факторов. При этом для всех ИНС-моделей 1–9 используется единая архитектура, имеющая 7 свёрточных слоёв. Различаются они лишь тем, что обучены на уникальных датасетах и, соответственно, имеют различные наборы коэффициентов межнейронных синаптических связей.

ЗАКЛЮЧЕНИЕ

Предложены одно- и многомодельный принципы классификации изображений ОКТ сетчатки глаза. Вычислительные эксперименты по автоматизированной классификации таких изображений, полученных с томографа DRI OCT Triton, с использованием различных архитектур ИНС-моделей показали точность при обучении и валидации 100%, и на дополнительном тесте — 85%, что является удовлетворительным результатом.

Выбрана оптимальная архитектура ИНС-модели — 6-слойная СНС — и определены значения её гиперпараметров. Указанные обстоятельства позволяют использовать разработки в системах поддержки принятия решений в области офтальмологии.

ДОПОЛНИТЕЛЬНАЯ ИНФОРМАЦИЯ

Источник финансирования. Авторы заявляют об отсутствии внешнего финансирования при проведении исследования.

Конфликт интересов. Авторы декларируют отсутствие явных и потенциальных конфликтов интересов, связанных с публикацией настоящей статьи.

Вклад авторов. Все авторы подтверждают соответствие своего авторства международным критериям ICMJE (все авторы внесли

существенный вклад в разработку концепции, проведение исследования и подготовку статьи, прочли и одобрили финальную версию перед публикацией). Наибольший вклад распределён следующим образом: А.А. Арзамасцев — разработка концепции, предварительная обработка изображений ОКТ, проведение исследования, написание программ, проведение вычислительных экспериментов, многомодельный подход к классификации изображений, подготовка рукописи; О.Л. Фабрикантов — разработка концепции, сбор и подготовка изображений ОКТ, многостадийная схема классификации изображений ОКТ; обсуждение и утверждение итогового варианта рукописи; Е.В. Кулагина — разработка методологии сбора и подготовки изображений ОКТ, проведение исследования, многостадийная схема классификации изображений ОКТ, утверждение итогового варианта рукописи; Н.А. Зенкова — разработка концепции, проведение исследования, редактирование и утверждение итогового варианта текста рукописи, анализ литературных данных, редактирование текста статьи.

Благодарности. Работа выполнена в соответствии с договором о научно-техническом сотрудничестве Воронежского государственного университета и Федерального государственного автономного учреждения «Национальный медицинский исследовательский центр «Межотраслевой научно-технический комплекс «Микрохирургия глаза» имени академика С.Н. Федорова», Тамбовского филиала от 28.11.2022.

В предварительных вычислительных экспериментах приняли участие магистранты факультета прикладной математики, информатики и механики Воронежского государственного университета, которые обучались по курсу «Системы искусственного интеллекта на базе искусственных нейронных сетей» в 2023 году в рамках лабораторного практикума: Е.П. Гализина, В.А. Гущина, И.О. Завьялова, В.Ю. Колупаев, Н.М. Кушнарёв, И.Ю. Новоскольцев, Е.А. Струкова, Н.М. Чернышов, И.Д. Чикуннов, А.А. Щеглевых, а также магистрант-дипломник М.А. Курприн. Эти работы выполнены под руководством одного из авторов статьи.

ADDITIONAL INFORMATION

Funding source. This study was not supported by any external sources of funding.

Competing interests. The authors declare that they have no competing interests.

Authors' contribution. All authors made a substantial contribution to the conception of the work, acquisition, analysis, interpretation of data for the work, drafting and revising the work, final approval of the version to be published and agree to be accountable for all aspects of the work.

А.А. Arzamastsev — development of the concept, preliminary processing of OCT images, conducting research, writing programs, conducting computational experiments, multi-model approach to image classification, preparation of the manuscript; O.L. Fabrikantov — development of the concept, collection and preparation of OCT images, multi-stage classification scheme for OCT images, discussion and approval of the final version of the

manuscript; E.V. Kulagina — development of a methodology for collecting and preparing OCT images, conducting research, a multi-stage classification scheme for OCT images, approval of the final version of the manuscript; N.A. Zenkova — concept development, research, editing and approval of the final version of the manuscript, analysis of literature data, editing the text of the article.

Acknowledgments. The work was carried out in accordance with the agreement on scientific and technical cooperation between Voronezh State University and the Federal State Autonomous Institution "National Medical Research Center" Interindustry Scientific

and Technical Complex "Eye Microsurgery" named after Academician S.N. Fedorov", Tambov branch dated November 28, 2022.

Master's degree students from the Faculty of Applied Mathematics, Informatics and Mechanics of Voronezh State University took part in the preliminary computational experiments: E.P. Galizina, V.A. Gushchina, I.O. Zavyalova, V.Yu. Kolupaev, N.M. Kushnarev, I.Yu. Novoskoltsev, E.A. Strukova, N.M. Chernyshov, I.D. Chikunov, A.A. Shcheglevatykh, as well as a diploma student M.A. Kuprin. These works were carried out under the guidance of one of the authors of the article.

СПИСОК ЛИТЕРАТУРЫ

1. Оптическая когерентная томография сетчатки / под ред. Дж.С. Дакера, Н.К. Вэхид, Д.Р. Голдмана. Москва : МЕДпресс-информ, 2021.
2. Oakden-Rayner L., Palme L.J. Artificial intelligence in medicine: Validation and study design. In: Ranschart E., Morozov S., Algra P., editors. *Artificial intelligence in medical imaging*. Cham : Springer, 2019. P. 83–104. doi: 10.1007/978-3-319-94878-2_8
3. Рамсундар Б., Истман П., Уолтерс П., Панде В. Глубокое обучение в биологии и медицине. Москва : ДМК Пресс, 2020.
4. Будума Н., Локашо Н. Основы глубокого обучения. Создание алгоритмов для искусственного интеллекта следующего поколения. Москва : Манн, Иванов и Фербер, 2020.
5. Фостер Д. Генеративное глубокое обучение. Творческий потенциал нейронных сетей. Санкт-Петербург : Питер, 2020.
6. Постолит А.В. Основы искусственного интеллекта в примерах на Python. Санкт-Петербург : БХВ-Петербург, 2021.
7. Арзамасцев А.А., Фабрикантов О.Л., Зенкова Н.А., Кулагина Е.В. Разработка программного обеспечения для анализа протоколов оптической когерентной томографии сетчатки глаза и автоматизированного составления их описаний // *Современные проблемы науки и образования*. 2021. № 6. EDN: PCVMRX doi: 10.17513/spno.31208
8. Васильев Ю.А., Владимирский А.В., Омелянская О.В., и др. Методология тестирования и мониторинга программного обе-

спечения на основе технологий искусственного интеллекта для медицинской диагностики // *Digital Diagnostics*. 2023. Т. 4, № 3. С. 252–267. doi: 10.17816/DD321971

9. Каталевская Е.А., Каталевский Д.Ю., Тюриков М.И., Шайхутдинова Э.Ф., Сизов А.Ю. Алгоритм сегментации визуальных признаков диабетической ретинопатии (ДР) и диабетического макулярного отёка (ДМО) на цифровых фотографиях глазного дна // *Российский журнал телемедицины и электронного здравоохранения*. 2021. Т. 7, № 4. С. 17–26. EDN: PPSPAL doi: 10.29188/2712-9217-2021-7-4-17-26
10. Kepp T., Sudkamp H., Burchard C., et al. Segmentation of retinal low-cost optical coherence tomography images using deep learning // *Medical Imaging 2020: Computer-Aided Diagnosis*. 2020. Vol. 11314. P. 389–396. doi: 10.48550/arXiv.2001.08480
11. Сахнов С.Н., Аксенов К.Д., Аксенова Л.Е., и др. Разработка модели скрининга катаракты с использованием открытого набора данных и алгоритмов глубокого машинного обучения // *Офтальмохирургия*. 2022. № 4S. С. 13–20. EDN: VEGPAW doi: 10.25276/0235-4160-2022-4S-13-20
12. Шухаев С.В., Мордовцева Е.А., Пустозеров Е.А., Кудлахмедов Ш.Ш. Применение сверточных нейронных сетей для определения эндотелиальной дистрофии Фукса // *Офтальмохирургия*. 2022. № 4S. С. 70–76. EDN: WEZTKV doi: 10.25276/0235-4160-2022-4S-70-76

REFERENCES

1. Daker DS, Vekhid NK, Goldman DR, editors. *Optical coherence tomography of the retina*. Moscow: MEDpress-inform; 2021. (In Russ).
2. Oakden-Rayner L, Palme LJ. Artificial intelligence in medicine: Validation and study design. In: Ranschart E, Morozov S, Algra P, editors. *Artificial intelligence in medical imaging*. Cham: Springer; 2019. P.83–104. doi: 10.1007/978-3-319-94878-2_8
3. Ramsundar B, Istman P, Uolters P, Pande V. *Deep learning in biology and medicine*. Moscow: DMK Press; 2020. (In Russ).
4. Buduma N, Lokasho N. *Foundations of deep learning. Creating Algorithms for Next Generation Artificial Intelligence*. Moscow: Mann, Ivanov i Ferber; 2020. (In Russ).
5. Foster D. *Generative deep learning. Creative potential of neural networks*. Saint Petersburg: Piter; 2020. (In Russ).
6. Postolit AV. *Fundamentals of Artificial Intelligence in Python examples*. Saint Petersburg: BKhV-Peterburg; 2021. (In Russ).
7. Arzamastsev AA, Fabrikantov OL, Zenkova NA, Kulagina EV. Software development for analysing the optical coherence tomography protocols of the retina and automatic composition of their descriptions. *Sovremennyye problemy nauki i obrazovaniya*. 2021;(6). EDN: PCVMRX doi: 10.17513/spno.31208
8. Vasiliev YA, Vlazimirsky AV, Omelyanskaya OV, et al. Methodology for testing and monitoring artificial intelligence-based software for medical diagnostics. *Digital Diagnostics*. 2023;4(3):252–267. doi: 10.17816/DD321971
9. Katalevskaya EA, Katalevsky DYU, Tyurikov MI, Shaykhutdinova EF, Sizov AYU. Algorithm for segmentation of visual signs of diabetic retinopathy (DR) and diabetic macular edema (DME) in digital fundus images. *Russian Journal of Telemedicine and e-health*. 2021;7(4):17–26. EDN: PPSPAL doi: 10.29188/2712-9217-2021-7-4-17-26

10. Kepp T, Sudkamp H, Burchard C, et al. Segmentation of retinal low-cost optical coherence tomography images using deep learning. *Medical Imaging 2020: Computer-Aided Diagnosis*. 2020;11314:389–396. doi: 10.48550/arXiv.2001.08480

11. Sakhnov SN, Axenov KD, Axenova LE, et al. Development of a cataract screening model using an open dataset and deep machine learning algorithms. *Fyodorov Journal*

of Ophthalmic Surgery. 2022;(4S):13–20. EDN: VEGPAW doi: 10.25276/0235-4160-2022-4S-13-20

12. Shukhaev SV, Mordovtseva EA, Pustozarov EA, Kudlakhmedov SS. Application of convolutional neural networks to define Fuchs endothelial dystrophy. *Fyodorov Journal of Ophthalmic Surgery*. 2022;(4S):70–76. EDN: WEZTKV doi: 10.25276/0235-4160-2022-4S-70-76

ОБ АВТОРАХ

* **Арзамасцев Александр Анатольевич**, д-р техн. наук, профессор;
адрес: Россия, 392000, г. Тамбов, ул. Лаврова, д. 24;
ORCID: 0000-0001-6795-2370;
eLibrary SPIN: 4410-6340;
e-mail: arz_sci@mail.ru

Фабрикантов Олег Львович, д-р мед. наук, профессор;
ORCID: 0000-0003-0097-991X;
eLibrary SPIN: 9675-9696;
e-mail: fabr-mntk@yandex.ru

Кулагина Елена Валерьевна;
ORCID: 0009-0006-0026-0832;
eLibrary SPIN: 8785-4949;
e-mail: irina-kulagin2015@yandex.ru

Зенкова Наталья Александровна, канд. психол. наук, доцент;
ORCID: 0000-0002-2325-1924;
eLibrary SPIN: 2266-4168;
e-mail: natulin@mail.ru

AUTHORS' INFO

* **Alexander A. Arzamastsev**, Dr. Sci. (Engineering), Professor;
address: 24 Lavrov street, 392000 Tambov, Russia;
ORCID: 0000-0001-6795-2370;
eLibrary SPIN: 4410-6340;
e-mail: arz_sci@mail.ru

Oleg L. Fabrikantov, MD, Dr. Sci. (Medicine), Professor;
ORCID: 0000-0003-0097-991X;
eLibrary SPIN: 9675-9696;
e-mail: fabr-mntk@yandex.ru

Elena V. Kulagina, MD;
ORCID: 0009-0006-0026-0832;
eLibrary SPIN: 8785-4949;
e-mail: irina-kulagin2015@yandex.ru

Natalia A. Zenkova, Cand. Sci. (Psychology), Assistant Professor;
ORCID: 0000-0002-2325-1924;
eLibrary SPIN: 2266-4168;
e-mail: natulin@mail.ru

* Автор, ответственный за переписку / Corresponding author

DOI: <https://doi.org/10.17816/DD624131>

Изучение возможностей программы искусственного интеллекта в диагностике заболеваний макулярной области

М.Р. Хабазова¹, Е.Н. Пономарева¹, И.А. Лоскутов², Е.А. Каталевская³,
А.Ю. Сизов^{3, 4}, Г.М. Габараев¹

¹ Федеральный научно-клинический центр специализированных видов медицинской помощи и медицинских технологий, Москва, Россия;

² Московский областной научно-исследовательский клинический институт имени М.Ф. Владимирского, Москва, Россия;

³ ООО «Диджитал Вижн Солюшнс», Москва, Россия;

⁴ Нижегородский государственный технический университет им. Р.Е. Алексеева, Нижний Новгород, Россия

АННОТАЦИЯ

Обоснование. Заболевания макулярной области представляют собой большую группу патологических состояний, приводящих к потере зрения и слабовидению. Ранняя диагностика таких изменений играет большую роль в выборе тактики лечения и является одной из определяющих в прогнозировании результатов.

Цель — изучить возможности программы искусственного интеллекта в диагностике заболеваний макулярной области на основе анализа сканов структурной оптической когерентной томографии.

Материалы и методы. В исследование были включены пациенты, проходившие обследование и лечение в Федеральном научно-клиническом центре специализированных видов медицинской помощи и медицинских технологий и Московского областного научно-исследовательского клинического института им. М.Ф. Владимирского. Обследовано 200 глаз с заболеваниями макулярной области, а также глаза без макулярной патологии. Проведён сравнительный клинический анализ сканов структурной оптической когерентной томографии, выполненных на офтальмологическом томографе RTVue XR 110-2. Для анализа сканов оптической когерентной томографии использовалось программное обеспечение Retina.AI.

Результаты. В ходе анализа сканов оптической когерентной томографии с помощью программы были выявлены различные патологические структуры макулярной области, а затем сформулировано заключение о вероятной патологии. Полученные результаты сравнивались с заключениями врачей-офтальмологов. Чувствительность метода составила 95,16%; специфичность — 97,76%; точность — 97,38%.

Заключение. Платформа Retina.AI позволяет офтальмологам успешно проводить автоматизированный анализ сканов структурной оптической когерентной томографии и выявлять различные патологические состояния глазного дна.

Ключевые слова: оптическая когерентная томография; искусственный интеллект; витреомакулярный интерфейс; диагностика; диабетический макулярный отёк; возрастная макулярная дегенерация.

Как цитировать:

Хабазова М.Р., Пономарева Е.Н., Лоскутов И.А., Каталевская Е.А., Сизов А.Ю., Габараев Г.М. Изучение возможностей программы искусственного интеллекта в диагностике заболеваний макулярной области // Digital Diagnostics. 2024. Т. 5, № 1. С. 17–28. DOI: <https://doi.org/10.17816/DD624131>

DOI: <https://doi.org/10.17816/DD624131>

Exploring the possibilities of an artificial intelligence program in the diagnosis of macular diseases

Margarita R. Khabazova¹, Elena N. Ponomareva¹, Igor A. Loskutov², Evgenia A. Katalevskaya³, Aleksandr Yu. Sizov^{3, 4}, Georgy M. Gabaraev¹

¹ Federal Research and Clinical Center of Specialized Medical Care and Medical Technologies, Moscow, Russia;

² Moscow Regional Research and Clinical Institute, Moscow, Russia;

³ Digital Vision Solutions LLC, Moscow, Russia;

⁴ Nizhny Novgorod State Technical University n.a. R.E. Alekseev, Nizhny Novgorod, Russia

ABSTRACT

BACKGROUND: Macular diseases are a large group of pathological conditions that cause vision loss and visual impairment. Early diagnosis of such changes plays an important role in treatment selection and is one of the crucial factors in predicting outcomes.

AIM: To examine the potential of an artificial intelligence program in the diagnosis of macular diseases using structural optical coherence tomography scans.

MATERIALS AND METHODS: The study included patients examined and treated at the Federal Research and Clinical Center of Specialized Medical Care and Medical Technologies and Moscow Regional Research and Clinical Institute. In total, 200 eyes with macular diseases were examined, as well as eyes without macular pathologies. A comparative clinical analysis of structural optical coherence tomography scans obtained using an RTVue XR 110-2 tomograph was conducted. The Retina.AI software was used to analyze optical coherence tomography scans.

RESULTS: In the analysis of optical coherence tomography scans using Retina.AI, various pathological structures of the macula were identified, and a probable pathology was then determined. The results were compared with the diagnoses made by ophthalmologists. The sensitivity, specificity, and accuracy of the method were 95.16%, 97.76%, and 97.38%, respectively.

CONCLUSION: Retina.AI allows ophthalmologists to automatically analyze optical coherence tomography scans and identify various pathological conditions of the fundus.

Keywords: optical coherence tomography; artificial intelligence; diagnosis; macular edema; age-related macular degeneration.

To cite this article:

Khabazova MR, Ponomareva EN, Loskutov IA, Katalevskaya EA, Sizov AYU, Gabaraev GM. Exploring the possibilities of an artificial intelligence program in the diagnosis of macular diseases. *Digital Diagnostics*. 2024;5(1):17–28. DOI: <https://doi.org/10.17816/DD624131>

DOI: <https://doi.org/10.17816/DD624131>

人工智能程序在黄斑疾病诊断中的可行性研究

Margarita R. Khabazova¹, Elena N. Ponomareva¹, Igor A. Loskutov²,
Evgenia A. Katalevskaya³, Aleksandr Yu. Sizov^{3,4}, Georgy M. Gabaraev¹

¹ Federal Research and Clinical Center of Specialized Medical Care and Medical Technologies, Moscow, Russia;

² Moscow Regional Research and Clinical Institute, Moscow, Russia;

³ Digital Vision Solutions LLC, Moscow, Russia;

⁴ Nizhny Novgorod State Technical University n.a. R.E. Alekseev, Nizhny Novgorod, Russia

摘要

论证。黄斑疾病是一大类病症。它们会导致视力丧失和视力低下。对这些病变的早期诊断对治疗策略的选择起着重要作用，它是疗效预测的决定性因素之一。

目的。本研究的目的是研究人工智能程序在基于对结构光学相干断层扫描图片的分析诊断黄斑疾病方面的可行性。

材料与方法。本研究对象包括在俄罗斯联邦医疗和生物局联邦专业医疗救护和医疗技术科学与临床中心以及以M. F. 弗拉基米尔斯基莫斯科州临床研究所接受检查和治疗的患者。对200只有黄斑病变的眼和无黄斑病变的眼进行了检查。对RTVue XR 110-2眼科断层扫描仪上的结构光学相干断层扫描进行了临床对比分析。利用Retina.AI软件对光学相干断层扫描进行分析。

结果。使用该程序分析光学相干断层扫描图片时，确定了黄斑区的各种病理结构。此外，还得出了关于可能病理的结论。对获得的结果与眼科医生的结论进行了比较。该方法的灵敏度为95.16%；特异性为97.76%；准确率为97.38%。

结论。Retina.AI平台使眼科医生能够成功地对结构光学相干断层扫描图片进行自动分析，并检测眼底的各种病理状态。

关键词：光学相干断层扫描；人工智能；玻璃体黄斑界面；诊断；糖尿病性黄斑水肿；老年性黄斑变性。

引用本文：

Khabazova MR, Ponomareva EN, Loskutov IA, Katalevskaya EA, Sizov AY, Gabaraev GM. 人工智能程序在黄斑疾病诊断中的可行性研究. *Digital Diagnostics*. 2024;5(1):17–28. DOI: <https://doi.org/10.17816/DD624131>

收到: 30.11.2023

接受: 02.02.2024

发布日期: 11.03.2024

ОБОСНОВАНИЕ

Согласно данным Всемирной организации здравоохранения, около 2,2 млрд человек в мире страдают нарушением зрения, большую группу составляют пациенты старше 50 лет [1]. Заболевания макулярной области, в особенности возрастная макулярная дегенерация (ВМД) и диабетический макулярный отёк (ДМО), занимают немалую часть среди причин необратимой слепоты и слабовидения [2].

На 2020 год в мире насчитывалось 196 миллионов пациентов с ВМД, и ожидается, что к 2040 году данная цифра достигнет 288 миллионов человек [3]. Клинически ВМД может проявляться отложениями друзеноидного материала, изменениями пигментного эпителия сетчатки, макулярной неоваскуляризацией, экссудацией и кровоизлияниями. На поздних стадиях отмечается географическая атрофия пигментного эпителия сетчатки [4]. Указанные проявления заболевания приводят к выраженным нарушениям со стороны органа зрения.

Количество пациентов, страдающих сахарным диабетом, неуклонно растёт. Вместе с этим наблюдается рост проявлений данного заболевания со стороны органа зрения. Прогнозируется, что к 2045 году число случаев диабетической ретинопатии (ДР) возрастёт до 160,50 млн, при этом количество пациентов с угрожающей зрению ДР достигнет 44,82 млн [5]. ДМО, встречающийся на различных стадиях ДР, является наиболее распространённой причиной потери зрения у пациентов с диабетом и ежегодно поражает почти 75 000 новых пациентов в Соединённых Штатах Америки [6]. Наблюдается прямая зависимость между частотой встречаемости ДМО и тяжестью ДР, 70% приходится на её пролиферативную стадию. Среди пациентов с сахарным диабетом 1-го типа у 27% ДМО развивается в течение 9 лет от начала заболевания [7]. В России насчитывается более 630 000 пациентов с различными стадиями ДР, при этом их распространённость среди пациентов с сахарным диабетом 1-го типа вдвое выше [8].

Четвёртое место среди заболеваний макулярной области, угрожающих снижением остроты зрения, занимает центральная серозная хориоретинопатия, характеризующаяся серозной отслойкой нейроэпителия, возникающей над зоной просачивания из хориокапилляров. Согласно исследованиям, частота встречаемости центральной серозной хориоретинопатии составляет 9,9 случая на 100 000 населения. Процесс чаще односторонний, но в 40% случаев наблюдается билатеральное поражение [9]. Хронизация процесса происходит в 5% случаев, тогда как рецидивы центральной серозной хориоретинопатии отмечаются у 30–50% пациентов в течение 12 месяцев [10].

Аномалии витреомакулярного интерфейса включают в себя сквозные и ламеллярные макулярные разрывы, витреомакулярную тракцию и эпиретинальную мембрану.

В ряде случаев изменения витреомакулярного интерфейса могут не вызывать выраженных функциональных нарушений, но при значительном воздействии на макулярную область отмечаются симптомы, сопровождающиеся значительным ухудшением зрения и негативно влияющие на качество жизни пациента. Распространённость макулярных разрывов составляет 3,3 случая на 1000 пациентов старше 55 лет [11]. Данные ежегодной заболеваемости варьируют от 4,71 до 8,5 человека на 100 000, согласно данным различных авторов [12].

В ходе 20-летнего наблюдения BDES (the Beaver Dam Eye Study) с помощью оптической когерентной томографии (ОКТ) было установлено, что распространённость эпиретинальной мембраны составляет 34,1%. Несмотря на различный патогенез заболевания, клинические проявления могут быть идентичными. Эпиретинальная мембрана может возникать как идиопатическое заболевание и в качестве сопутствующей патологии на фоне предшествующих офтальмологических заболеваний, таких как ДР, окклюзия вен сетчатки, перенесённая ранее операция удаления катаракты [13]. Возникновение эпиретинальной мембраны, не сопровождающееся задней отслойкой стекловидного тела, предрасполагает к формированию макулярного отёка и ламеллярного макулярного разрыва, обусловленного тангенциальным тракционным синдромом [14].

В настоящее время, когда продолжительность жизни населения увеличивается, особенно актуально раннее выявление заболеваний, развивающихся с возрастом. Известно, что своевременное выявление заболевания играет важную роль в лечении и является одним из основных этапов снижения уровня заболеваемости. Поскольку ДМО и ВМД остаются ведущими причинами снижения остроты зрения, регулярный офтальмологический скрининг на данные патологии необходим для выявления пациентов, нуждающихся в специализированном офтальмологическом лечении. Такая тактика позволит предотвратить развитие слепоты на ранних этапах [15]. Своевременное начало лечения часто является залогом благоприятного исхода с положительными морфологическими и функциональными результатами (в первую очередь, остротой зрения).

Терапия ингибиторами фактора роста эндотелия сосудов (анти-VEGF) — золотой стандарт лечения неоваскулярной формы ВМД и ДМО [16]. На сегодняшний день существуют различные протоколы ведения пациентов с указанными заболеваниями. Во всех предложенных протоколах используется оценка проводившегося лечения, основанная на клинических исследованиях и данных ОКТ, которая требует регулярности проведения. В настоящее время ОКТ является наиболее информативным и широко применяемым методом диагностики патологии сетчатки и обеспечивает точный мониторинг в ходе терапии. На базе данных ОКТ не только производится оценка настоящего состояния макулярной области,

но и подбирается необходимая в данном конкретном случае тактика лечения.

Рост числа пациентов с заболеваниями макулярной области, которые нуждаются в регулярных офтальмологических обследованиях, создаёт ощутимую нагрузку на систему здравоохранения. Необходимость за ограниченный период времени провести диагностику большого количества пациентов, оценить полученные данные и определить тактику лечения требует значительных трудовых и временных ресурсов, что может создать их некоторый дефицит. Решение данной проблемы возможно в разработке и внедрении в клиническую практику новых инновационных методов анализа офтальмологических изображений и использование технологий искусственного интеллекта (ИИ) [17].

Благодаря развитию методов ИИ в настоящее время существует целое направление, занимающееся разработкой и внедрением интеллектуальных систем в деятельность врача. В России на период до 2030 года утверждена Национальная стратегия развития ИИ¹.

В России и во всём мире ведутся работы по созданию и валидации в клинической практике программ ИИ для диагностики патологии сетчатки. Авторы проекта компании Google DeepMind (Англия, США) провели исследование на широком спектре изображений, взятых из клинической практики 32 офтальмологических клиник, которые охватывали различные группы населения. Результат диагностики изображений может быть использован для количественной оценки морфологии сетчатки и получения результатов измерений конкретных патологий. Программа компании способна сортировать снимки с высокой эффективностью, соответствующей или превосходящей специалистов. Авторы работы проводили исследование на 53 патологиях, относящихся к национальным направлениям. Согласно их заключению, они представили новую систему, способную качественно и эффективно анализировать клинические ОКТ-снимки и давать рекомендации. В будущем они планируют сосредоточиться на большем количестве клинических патологий и расширить спектр своей работы.

Программа RetInSight, разработанная сотрудниками Венского университета (Австрия) под руководством профессора U. Schmidt-Erfurth, предназначена для мониторинга эффективности лечения неоваскулярной формы ВМД при помощи алгоритмов ИИ. Программа основана на принципе сегментации интравитреальной и субретинальной жидкости, а также отслойки ретинального пигментного эпителия, с динамической оценкой объёмов перечисленных структур [18].

Чикагская компания Altris Inc. (США) анонсировала запуск программы Altris AI, предназначенной для автоматического анализа ОКТ-сканов. Согласно данным,

представленным разработчиками, облачная платформа обеспечивает быстрый анализ и визуализацию 100 патологий и патологических признаков, включая редкие. Заложенные алгоритмы способны диагностировать глаукому, ВМД, ДР и другие заболевания сетчатки. Пользователям доступны модули, осуществляющие скрининг, сегментацию/классификацию и отчёты [19].

В работе Б.Э. Малюгина и соавт. [20] внимание уделяется созданию алгоритма автоматизированного обнаружения биомаркёров эффективности анти-VEGF-терапии у пациентов в ВМД. Было выделено 7 биомаркёров: отслойка пигментного эпителия, пигментный эпителий, субретинальная жидкость, интравитреальная жидкость, эллипсоидная зона, слой нервных волокон сетчатки, субретинальный гиперрефлективный материал. Для отслойки пигментного эпителия сетчатки индекс Дайса составил 0,8, для пигментного эпителия и субретинальной жидкости — 0,4, а для остальных биомаркёров — от 0,3 до 0,15. В дальнейшем планируется расширение набора данных для обучения и повышение точности работы [20].

ЦЕЛЬ

Изучение возможностей программы ИИ в диагностике макулярной патологии на основе анализа сканов структурной ОКТ.

МАТЕРИАЛЫ И МЕТОДЫ

Дизайн исследования

Сканы структурной ОКТ, представленные для исследования, были получены на офтальмологическом томографе RTVue XR 110-2 (Optovue, США). Для анализа сканов ОКТ использовалось программное обеспечение для работы с цифровыми медицинскими изображениями на основе алгоритмов ИИ Retina.AI (ООО «Диджитал Вижн Солюшнс», Россия). Исследование проводилось согласно дизайну не меньшей эффективности и представляло собой одноцентровое ретроспективное наблюдательное выборочное неконтролируемое исследование.

Критерии соответствия

Критерии включения:

- ранее установленный диагноз «диабетический макулярный отёк», возрастная макулярная дегенерация (сухой и экссудативной форм), центральная серозная хориопатия, витреомакулярный тракционный синдром (витреомакулярной тракции, эпиретинальной мембраны, сквозного и ламеллярного макулярных разрывов);
- сниженная острота центрального зрения и подозрение на наличие патологии макулярной области.

¹ Указ Президента Российской Федерации № 490 от 10 октября 2019 г. «О развитии искусственного интеллекта в Российской Федерации». Режим доступа: <http://www.kremlin.ru/acts/bank/44731>

Критерии исключения:

- невозможность проведения ОКТ вследствие выраженного нарушения прозрачности оптических сред (помутнение роговицы, зрелая катаракта, гифема, гемофтальм и др.);
- невозможность фиксации взгляда пациента (нистагм, паркинсонизм и др.).

Анализ в подгруппах

В исследовании участвовало 129 пациентов, средний возраст составил 65,9 года. Женщины составили 55,8% (72 человека) общего числа участников, мужчины — 44,2% (57 человек). Было обследовано 200 глаз со следующими нозологиями:

- диабетический макулярный отёк;
- кистозный макулярный отёк;
- ВМД (макулярная неоваскуляризация, ретинальные друзы);
- центральная серозная хориопатия;
- витреомакулярный тракционный синдром;
- сквозной макулярный разрыв;
- ламеллярный макулярный разрыв;
- эпиретинальная мембрана.

Были обследованы также глаза без макулярной патологии. Распределение по нозологиям представлено в табл. 1.

Условия проведения

В ходе представленного исследования проводился сравнительный клинический анализ сканов структурной ОКТ пациентов, проходивших обследование и лечение в Федеральном государственном бюджетном учреждении «Федеральный научно-клинический центр специализированных видов медицинской помощи и медицинских технологий Федерального Медико-биологического агентства»

Таблица 1. Распределение обследованных глаз по нозологиям

Диагноз	Количество глаз
Диабетический макулярный отёк/ кистозный макулярный отёк	52
Возрастная макулярная дегенерация: макулярная неоваскуляризация	41
Возрастная макулярная дегенерация: ретинальные друзы	40
Центральная серозная хориопатия	25
Витреомакулярный тракционный синдром	25
Сквозной макулярный разрыв	23
Ламеллярный макулярный разрыв	25
Эпиретинальная мембрана	72
Без патологии	34

России и Государственном бюджетном учреждении здравоохранения Московской области «Московский областной научно-исследовательский клинический институт имени М.Ф. Владимирского». Продолжительность исследования — 12 месяцев.

Описание медицинского вмешательства и основной исход исследования

Анализ сканов структурной ОКТ программой ИИ производился в два этапа. На первом этапе программой сегментировались биомаркёры. На втором этапе программа вычисляла вероятную патологию при помощи алгоритма дифференциально-диагностического поиска. Заключение, полученное в ходе анализа сканов ОКТ программой ИИ, сравнивалось с данными клинического заключения двух врачей-офтальмологов.

Этическая экспертиза

Этический комитет при Федеральном государственном бюджетном учреждении «Федеральный научно-клинический центр специализированных видов медицинской помощи и медицинских технологий Федерального Медико-биологического агентства» России, выписка 2 из протокола № 11_2022 от 29 ноября 2022 г. Заключение: «Одобрить возможность проведения ретроспективного анализа фотографий глазного дна и сканов ОКТ пациентов, отобранных из медицинских баз с применением программного обеспечения для работы с цифровыми изображениями при диагностике офтальмологических патологий путём анализа фотографий глазного дна и сканов структурной ОКТ Retina.AI по ТУ 58.29.32-001-60003594-2022 на базе ФГБУ Федерального научно-клинического Центра специализированных видов медицинской помощи и медицинских технологий ФМБА России».

Методы регистрации исходов, статистический анализ

С целью оценки точности работы программы вычислялись следующие параметры:

- количество правильных положительных срабатываний — TP (True positives);
- количество неправильных положительных срабатываний — FP (False positives);
- количество неправильных отрицательных срабатываний — FN (False negatives);
- количество правильных отрицательных срабатываний — TN (True negatives).

На основе представленных параметров рассчитывались показатели чувствительности, специфичности и точности для каждой из нозологий по указанным ниже формулам:

Precision (точность срабатывания) — доля правильных положительных случаев из предсказанных положительных случаев:
$$\text{Precision} = \frac{TP}{(TP + FP)}$$

Recall/Sensitivity (чувствительность) — доля правильно предсказанных положительных случаев из всех положительных случаев:
$$\text{Recall} = \frac{TP}{(TP + FN)}$$

Specificity (специфичность) — доля правильно предсказанных отрицательных случаев из всех отрицательных случаев:
$$\text{Specificity} = \frac{TN}{(TN + FP)} \text{ [17].}$$

РЕЗУЛЬТАТЫ

Объекты (участники) исследования, основные результаты исследования

Объект исследования — программное обеспечение для работы с цифровыми медицинскими изображениями при диагностике офтальмологических патологий путём анализа сканов структурной ОКТ — Retina.AI. Исследование проводилось без участия пациентов, в форме оценки и анализа клинических данных.

В ходе анализа сканов ОКТ с помощью программы были выявлены следующие патологические структуры:

- интравитреальные кисты, субретинальная жидкость;
- отслойка ретинального пигментного эпителия;
- субретинальный гиперрефлективный материал;
- ретинальные друзы;
- эпиретинальная мембрана;
- витреомакулярная тракция;
- сквозной макулярный разрыв;
- ламеллярный макулярный разрыв.

На основании выявленных патологических признаков программой в автоматическом режиме формулировалось заключение. Общие показатели метода следующие: чувствительность 95,16%; специфичность 97,76%; точность 97,38%. Подробные результаты сравнительного анализа заключений программы ИИ и врачей-офтальмологов представлены в табл. 2.

На рис. 1 представлен скан структурной ОКТ макулярной зоны пациента Б., 54 года, с сахарным диабетом 2-го типа. По данным заключения врача-офтальмолога, выявлен диагноз «диабетический макулярный отёк». В процессе программного анализа скана структурной ОКТ алгоритмами ИИ Retina.AI сегментированы следующие патологические признаки: интравитреальные кисты, субретинальная жидкость. В заключении диагностирован диабетический макулярный отёк.

На рис. 2 представлен скан структурной ОКТ макулярной зоны пациента Б., 68 лет, с экссудативной формой ВМД. Диагноз установлен врачом-офтальмологом. В процессе программного анализа скана структурной ОКТ алгоритмами ИИ Retina.AI сегментированы следующие патологические признаки: интравитреальные кисты, субретинальная жидкость, отслойка ретинального пигментного эпителия, субретинальный гиперрефлективный материал. Согласно данным отчёта программы, зарегистрирована макулярная неоваскуляризация.

На рис. 3 представлен скан структурной ОКТ макулярной зоны пациентки К., 69 лет, с диагнозом, установленным врачом-офтальмологом: «сквозной макулярный разрыв». В процессе анализа скана структурной ОКТ алгоритмами ИИ Retina.AI выделены следующие патологические структуры: сквозной макулярный разрыв, интравитреальные кисты, эпиретинальная мембрана. Согласно данным отчёта программы, диагностирован сквозной макулярный разрыв, эпиретинальная мембрана.

Нежелательные явления

Нежелательные явления, возникшие в ходе проведения исследования, отсутствовали.

ОБСУЖДЕНИЕ

Резюме основного результата исследования

Программное обеспечение на основе алгоритмов ИИ Retina.AI в ходе клинического исследования продемонстрировало высокие показатели чувствительности, специфичности и точности в диагностике макулярной

Таблица 2. Чувствительность, специфичность и точность программы Retina.AI в диагностике заболеваний макулярной области

Диагноз	Чувствительность, %	Специфичность, %	Точность, %
Диабетический макулярный отёк/кистозный макулярный отёк	96,08	97,48	97,14
Макулярная неоваскуляризация	97,50	97,65	97,62
Возрастная макулярная дегенерация: ретинальные друзы	97,37	96,51	96,67
Центральная серозная хориопатия	92,59	98,36	97,62
Витреомакулярная тракция	86,96	97,33	96,19
Сквозной макулярный разрыв	95,65	98,40	98,10
Эпиретинальная мембрана	100,00	97,12	98,10
Ламеллярный макулярный разрыв	95,83	97,85	97,62
Без патологии	94,72	97,69	97,25




Рис. 1. Пример анализа скана структурной оптической когерентной томографии макулярной зоны пациента с диабетическим макулярным отёком программой искусственного интеллекта: *a* — скан структурной оптической когерентной томографии; *b* — скан структурной оптической когерентной томографии после сегментации патологических структур (субретинальная жидкость — зелёная маска, интраретинальные кисты — голубые маски); *c* — отчёт по результатам анализа скана (в таблице дифференциально-диагностического поиска в качестве вероятной патологии красным цветом выделен диабетический макулярный отёк).




Рис. 2. Пример анализа скана структурной оптической когерентной томографии макулярной зоны пациента с экссудативной формой возрастной макулярной дегенерации программой искусственного интеллекта: *a* — скан структурной оптической когерентной томографии; *b* — скан структурной оптической когерентной томографии после сегментации патологических структур (субретинальная жидкость — зелёные маски, интраретинальные кисты — голубые маски, отслойка ретикулярного пигментного эпителия — оранжевые маски, субретинальный гиперрефлективный материал — салатная маска); *c* — отчёт по результатам анализа скана (в таблице дифференциально-диагностического поиска в качестве вероятной патологии красным цветом выделена макулярная неоваскуляризация).

патологии — показатели превысили 90% для всех заболеваний, за исключением витреомacularного тракционного синдрома, чувствительность в диагностике которого составила 86,96%. Положительной стороной программного

обеспечения является удобный пользовательский интерфейс с возможностью подсветки выявленных патологических структур на скане ОКТ, что даёт возможность врачу дополнительно перепроверить корректность




Рис. 3. Пример анализа скана структурной оптической когерентной томографии макулярной зоны пациента с диагнозом «макулярный разрыв, эпиретинальная мембрана» программой искусственного интеллекта: *a* — скан структурной оптической когерентной томографии; *b* — скан структурной оптической когерентной томографии после сегментации патологических структур (сквозной макулярный разрыв — фиолетовая маска, интраретинальные кисты — голубые маски, эпиретинальная мембрана — красные маски); *c* — отчёт по результатам анализа скана (в таблице дифференциально-диагностического поиска в качестве вероятной патологии красным цветом выделены эпиретинальная мембрана, сквозной макулярный разрыв).

работы программы и повышает уровень доверия врача технологии ИИ.

Обсуждение основного результата исследования

С практической точки зрения одним из наиболее перспективных направлений внедрения технологий ИИ в клиническую работу является их использование при проведении скрининговых обследований, когда возникает необходимость обследовать большое количество пациентов и выявить нуждающихся в специализированном офтальмологическом лечении. Технологии ИИ открывают возможность делегирования части функционала среднему медицинскому персоналу и организации доврачебного скрининга с целью высвобождения времени врача для более сложных задач и увеличения пропускной способности офтальмологического кабинета. Следует, однако, подчеркнуть, что технологии ИИ не могут служить заменой врача-офтальмолога, а могут быть лишь инструментом, позволяющим повысить эффективность лечебно-диагностического процесса. Определённые сложности внедрения программы ИИ могут быть обусловлены необходимостью использования стабильного интернет-соединения в связи с тем, что платформа расположена в «облачном пространстве». Для удобства работы в непрерывном режиме перспективным является разработка десктопного приложения, не зависящего от наличия интернета на устройстве.

Другим перспективным направлением использования технологий ИИ является мониторинг патологического процесса в ходе лечения. Сегментация интраретинальных

кист, субретинальной жидкости, отслойки пигментного эпителия, субретинального гиперрефлективного материала позволяет проводить количественную оценку динамики объёмов данных структур у пациентов с ДМО и экссудативной формой ВМД в ходе анти-VEGF терапии. На сегодняшний день основными количественными показателями, на которые ориентируется врач в процессе лечения, являются максимальная скорректированная острота зрения, толщина центральной зоны сетчатки, а также площадь неоваскулярной мембраны у пациентов с ВМД по данным ОКТ-ангиографии. Разработка новых количественных критериев оценки эффективности анти-VEGF терапии — актуальная задача для совместной работы врачей-офтальмологов и разработчиков алгоритмов ИИ.

Некоторым ограничением использования применяемой нами технологии является оценка единичного скана ОКТ, загруженного в программу. Актуально усовершенствование программного обеспечения, что позволит в последующем производить анализ всей серии снимков одного пациента.

ЗАКЛЮЧЕНИЕ

Программное обеспечение Retina.AI на основе алгоритмов ИИ в ходе клинической валидации продемонстрировало высокие показатели чувствительности, специфичности и точности в диагностике ДМО, сухой и экссудативной формы ВМД, центральной серозной хориопатии и аномалий витреомacularного интерфейса на основе анализа сканов структурной ОКТ. Платформа Retina.AI является российской разработкой и в настоящее время доступна

для тестирования по ссылке: www.screenretina.ru. Стоит отметить, что заключение программы не является диагнозом и требует уточнения специалиста.

А.Ю. Сизов — разработка алгоритмов ИИ, разметка данных, подготовка графических материалов; Г.М. Габараев — поиск литературы, обработка данных.

ДОПОЛНИТЕЛЬНАЯ ИНФОРМАЦИЯ

Источник финансирования. Авторы заявляют об отсутствии внешнего финансирования при проведении исследования.

Конфликт интересов. Е.А. Каталевская и А.Ю. Сизов входят в состав разработчиков программного обеспечения. Остальные авторы декларируют отсутствие явных и потенциальных конфликтов интересов, связанных с публикацией настоящей статьи.

Вклад авторов. Все авторы подтверждают соответствие своего авторства международным критериям ICMJE (все авторы внесли существенный вклад в разработку концепции, проведение исследования и подготовку статьи, прочли и одобрили финальную версию перед публикацией). Наибольший вклад распределён следующим образом: М.Р. Хабазова — поиск и обработка литературы, обработка данных, написание текста статьи, коррекция текста; Е.Н. Пономарева — проведение исследований, анализ данных, коррекция текста; И.А. Лоскутов — обсуждение результатов исследования, редактирование текста статьи; Е.А. Каталевская — разработка алгоритмов ИИ, разметка данных, редактирование текста статьи, обработка литературы и данных;

ADDITIONAL INFORMATION

Funding source. This study was not supported by any external sources of funding.

Competing interests. Katalevskaya EA and Sizov AYU are part of the software developers. Other authors declare that they have no competing interests.

Authors' contribution. All authors made a substantial contribution to the conception of the work, acquisition, analysis, interpretation of data for the work, drafting and revising the work, final approval of the version to be published and agree to be accountable for all aspects of the work. Khabazova MR — literature search and analysis, data analysis, manuscript writing, manuscript editing; Ponomareva EN — conducting research, data analysis, manuscript editing; Loskutov IA — discussion of the research results, editing; Katalevskaya EA — development of the artificial intelligence algorithms, data markup, manuscript editing, literature search and analysis; Sizov AYU — development of the artificial intelligence algorithms, data markup, graphic materials preparation; Gabaraev GM — literature search, data analysis.

СПИСОК ЛИТЕРАТУРЫ

1. Report of the 2030 targets on effective coverage of eye care [Internet]. Geneva : World Health Organization. c2024. [дата обращения: 1.01.2023]. Доступ по ссылке: <https://www.who.int/publications/i/item/9789240058002>
2. GBD 2019 Blindness and Vision Impairment Collaborators. Causes of blindness and vision impairment in 2020 and trends over 30 years, and prevalence of avoidable blindness in relation to VISION 2020: the Right to Sight: an analysis for the Global Burden of Disease Study // *Lancet Glob Health*. 2021. Vol. 9, N 2. P. 144–160. doi: 10.1016/S2214-109X(20)30489-7
3. Samanta A., Aziz A.A., Jhingan M., et al. Emerging Therapies in Neovascular Age-Related Macular Degeneration in 2020 // *Asia Pac J Ophthalmol* (Phila). 2020. Vol. 9, N 3. P. 250–259. doi: 10.1097/APO.0000000000000291
4. Stahl A. The Diagnosis and Treatment of Age-Related Macular Degeneration // *Dtsch Arztebl Int*. 2020. Vol. 117. P. 513–520. doi: 10.3238/arztebl.2020.0513
5. Teo Z.L., Tham Y.C., Yu M., et al. Global Prevalence of Diabetic Retinopathy and Projection of Burden through 2045: Systematic Review and Meta-analysis // *Ophthalmology*. 2021. Vol. 128, N 11. P. 1580–1591. doi: 10.1016/j.ophtha.2021.04.027
6. Schaal S., Kaplan H.J., editors. Cystoid Macular Edema. Switzerland : Springer International Publishing, 2017. doi: 10.1007/978-3-319-39766-5
7. Бикбов М.М., Файзрахманов Р.Р., Зайнуллин Р.М., и др. Макулярный отёк как проявление диабетической ретинопатии // *Сахарный диабет*. 2017. Т. 20, № 4. С. 263–269. EDN: ZMZAON doi: 10.14341/DM8328
8. Черных Д.В., Черных В.В., Трунов А.Н. Цитокины и факторы роста в патогенезе пролиферативной диабетической ретинопатии. Москва : Офтальмология, 2017. EDN: ZNDEWH
9. Gupta A., Tripathy K. Central Serous Chorioretinopathy [Internet]. [Updated 2022 Aug 22]. In: StatPearls [Internet]. Treasure Island (FL): StatPearls Publishing, 2022. Доступ по ссылке: <https://www.statpearls.com/point-of-care/96027>
10. Semeraro F., Morescalchi F., Russo A., et al. Central Serous Chorioretinopathy: Pathogenesis and Management // *Clinical ophthalmology*. 2019. Vol. 13. P. 2341–2352. doi: 10.2147/OPHT.S220845
11. Oh K.T., Lazzaro D.R., editors. Macular Hole. [Internet]. Medscape, 2020. [Дата обращения: 02.01.2020]. Доступ по ссылке: <https://emedicine.medscape.com/article/1224320-overview#a6>
12. Darian-Smith E., Howie A.R., Allen P.L., et al. Tasmanian macular hole study: whole population-based incidence of full thickness macular hole // *Clin Exp Ophthalmol*. 2016. Vol. 44, N 9. P. 812–816. doi: 10.1111/ceo.12801
13. Fung A.T., Galvin J., Tran T. Epiretinal membrane: A review // *Clin Experiment Ophthalmol*. 2021. Vol. 49. P. 289–308. doi: 10.1111/ceo.13914
14. Oh K.T., Lazzaro D.R., editors. Epiretinal Membrane [Internet]. Medscape, 2020. [Дата обращения: 02.01.2020]. Доступ по ссылке: <https://emedicine.medscape.com/article/1223882-overview#a4>
15. Всемирная организация здравоохранения. Европейское региональное бюро. Скрининг на диабетическую ретинопатию: Повышение эффективности, максимальное увеличение пользы и минимизация вреда, краткое руководство [Internet]. Копенгаген,

2021. [Дата обращения: 02.01.2020]. Доступ по ссылке: <https://www.who.int/europe/publications/i/item/9789289055321>

16. Qassimi A.N., Kozak I., Karam A.M., et al. Management of Diabetic Macular Edema: Guidelines from the Emirates Society of Ophthalmology // *Ophthalmology and therapy*. 2022. Vol. 11. P. 1937–1950. doi: 10.1007/s40123-022-00547-2

17. Каталевская Е.А., Каталевский Д.Ю., Тюриков М.И., Велиева И.А., Большунов А.В. Перспективы использования искусственного интеллекта в диагностике и лечении заболеваний сетчатки // *РМЖ. Клиническая офтальмология*. 2022. Т. 22, № 1. С. 36–43. EDN: AEBQGU doi: 10.32364/2311-7729-2022-22-1-36-43

18. Schmidt-Erfurth U., Reiter G.S., Riedl S., et al. AI-based monitoring of retinal fluid in disease activity and under therapy // *Prog Retin Eye Res*. 2022. Vol. 86. doi: 10.1016/j.preteyeres.2021.100972

19. Altris.ai [Internet]. United States : Altris Inc. [Дата обращения: 01.01.2022]. Доступ по ссылке: <https://www.altris.ai>

20. Малугин Б.Э., Сахнов С.Н., Аксенова Л.Е., и др. Разработка модели глубокого машинного обучения для обнаружения биомаркеров анатомического и функционального исхода анти-VEGF-терапии на ОКТ-изображениях сетчатки // *Офтальмохирургия*. 2022. № S4. С. 77–84. EDN: OWQLRM doi: 10.25276/0235-4160-2022-4S-77-84

REFERENCES

1. Report of the 2030 targets on effective coverage of eye care [Internet]. Geneva: World Health Organization. c2024. [cited 2023 Jan 1]. Available from: <https://www.who.int/publications/i/item/9789240058002>

2. GBD 2019 Blindness and Vision Impairment Collaborators. Causes of blindness and vision impairment in 2020 and trends over 30 years, and prevalence of avoidable blindness in relation to VISION 2020: the Right to Sight: an analysis for the Global Burden of Disease Study. *Lancet Glob Health*. 2021;9(2):144–160. doi: 10.1016/S2214-109X(20)30489-7

3. Samanta A, Aziz AA, Jhingan M, et al. Emerging Therapies in Neovascular Age-Related Macular Degeneration in 2020. *Asia Pac J Ophthalmol (Phila)*. 2020;9(3):250–259. doi: 10.1097/APO.0000000000000291

4. Stahl A. The Diagnosis and Treatment of Age-Related Macular Degeneration. *Dtsch Arztebl Int*. 2020;117:513–520. doi: 10.3238/arztebl.2020.0513

5. Teo ZL, Tham YC, Yu M, et al. Global Prevalence of Diabetic Retinopathy and Projection of Burden through 2045: Systematic Review and Meta-analysis. *Ophthalmology*. 2021;128(11):1580–1591. doi: 10.1016/j.ophtha.2021.04.027

6. Schaal S, Kaplan HJ, editors. *Cystoid Macular Edema*. Switzerland: Springer International Publishing; 2017. doi: 10.1007/978-3-319-39766-5

7. Bikbov MM, Fayzrakhmanov RR, Zaynullin RM, et al. Macular oedema as manifestation of diabetic retinopathy. *Diabetes mellitus*. 2017;20(4):263–269. EDN: ZMZAON doi: 10.14341/DM8328

8. Chernykh DV, Chernykh VV, Trunov AN. *Cytokines and growth factors in the pathogenesis of proliferative diabetic retinopathy*. Moscow: Oftal'mologiya; 2017. EDN: ZNDEWH

9. Gupta A, Tripathy K. Central Serous Chorioretinopathy [Internet]. [Updated 2022 Aug 22]. In: StatPearls [Internet]. Treasure Island (FL): StatPearls Publishing, 2022. Available from: <https://www.statpearls.com/point-of-care/96027>

10. Semeraro F, Morescalchi F, Russo A, et al. Central Serous Chorioretinopathy: Pathogenesis and Management. *Clinical ophthalmology*. 2019;13:2341–2352. doi: 10.2147/OPTH.S220845

11. Oh KT, Lazzaro DR, editors. Macular Hole. [Internet]. Medscape, 2020. [cited 2020 Jan 02]. Available from: <https://emedicine.medscape.com/article/1224320-overview#a6>

12. Darian-Smith E, Howie AR, Allen PL, et al. Tasmanian macular hole study: whole population-based incidence of full thickness macular hole. *Clinical & Experimental Ophthalmology*. 2016;44(9):812–816. doi: 10.1111/ceo.12801

13. Fung AT, Galvin J, Tran T. Epiretinal membrane: A review. *Clinical & Experimental Ophthalmology*. 2021;49:289–308. doi: 10.1111/ceo.13914

14. Oh KT, Lazzaro DR, editors. Epiretinal Membrane [Internet]. Medscape, 2020. [cited 2020 Jan 02]. Available from: <https://emedicine.medscape.com/article/1223882-overview#a4>

15. World Health Organization. Regional Office for Europe. Screening for diabetic retinopathy: a short guide. Increase effectiveness, maximize benefits and minimize harm [Internet]. Copenhagen; 2021. [cited 2020 Jan 02]. Available from: <https://www.who.int/europe/publications/i/item/9789289055321>

16. Qassimi AN, Kozak I, Karam AM, et al. Management of Diabetic Macular Edema: Guidelines from the Emirates Society of Ophthalmology. *Ophthalmology and therapy*. 2022;11:1937–1950. doi: 10.1007/s40123-022-00547-2

17. Katalevskaya EA, Katalevskiy DYU, Tyurikov MI, Velieva IA, Bol'shunov AV. Future of artificial intelligence for the diagnosis and treatment of retinal diseases. *Russian journal of clinical ophthalmology*. 2022;22(1):36–43. EDN: AEBQGU doi: 10.32364/2311-7729-2022-22-1-36-43

18. Schmidt-Erfurth U, Reiter GS, Riedl S, et al. AI-based monitoring of retinal fluid in disease activity and under therapy. *Prog Retin Eye Res*. 2022;86. doi: 10.1016/j.preteyeres.2021.100972

19. Altris.ai [Internet]. United States: Altris Inc. [cited 2022 Jan 01]. Available from: <https://www.altris.ai>

20. Malyugin BE, Sakhnov SN, Axenova LE, et al. A deep machine learning model development for the biomarkers of the anatomical and functional anti-VEGF therapy outcome detection on retinal OCT images. *Fyodorov Journal of Ophthalmic Surgery*. 2022;(S4):77–84. EDN: OWQLRM doi: 10.25276/0235-4160-2022-4S-77-84

ОБ АВТОРАХ

*** Хабазова Маргарита Робертовна;**

адрес: Российская Федерация, 115682, г. Москва,
Ореховый бульвар, д. 28;
ORCID: 0000-0002-7770-575X;
eLibrary SPIN: 2736-9089;
e-mail: rita.khabazova@mail.ru

Пономарева Елена Николаевна;

ORCID: 0009-0001-0828-9844;
eLibrary SPIN: 7868-4425;
e-mail: ponomareva.en@fnkc-fmba.ru

Лоскутов Игорь Анатольевич, д-р мед. наук;

ORCID: 0000-0003-0057-3338;
eLibrary SPIN: 5845-6058;
e-mail: loskoutigor@mail.ru

Каталевская Евгения Алексеевна, канд. мед. наук;

ORCID: 0000-0002-5710-9205;
eLibrary SPIN: 7849-8890;
e-mail: ekatalevskaya@mail.ru

Сизов Александр Юрьевич;

ORCID: 0000-0003-3338-4015;
eLibrary SPIN: 4468-1730;
e-mail: sizov_ost_vk@mail.ru

Габараев Георгий Малхазович;

ORCID: 0000-0002-0759-3107;
eLibrary SPIN: 1802-3224;
e-mail: geor_gabaraev1@mail.ru

AUTHORS' INFO

*** Margarita R. Khabazova;**

address: 28 Orekhovyi bul'var, 115682
Moscow, Russia;
ORCID: 0000-0002-7770-575X;
eLibrary SPIN: 2736-9089;
e-mail: rita.khabazova@mail.ru

Elena N. Ponomareva;

ORCID: 0009-0001-0828-9844;
eLibrary SPIN: 7868-4425;
e-mail: ponomareva.en@fnkc-fmba.ru

Igor A. Loskutov, MD, Dr. Sci. (Medicine);

ORCID: 0000-0003-0057-3338;
eLibrary SPIN: 5845-6058;
e-mail: loskoutigor@mail.ru

Evgenia A. Katalevskaya, MD, Cand. Sci. (Medicine);

ORCID: 0000-0002-5710-9205;
eLibrary SPIN: 7849-8890;
e-mail: ekatalevskaya@mail.ru

Alexander Yu. Sizov;

ORCID: 0000-0003-3338-4015;
eLibrary SPIN: 4468-1730;
e-mail: sizov_ost_vk@mail.ru

Georgiy M. Gabaraev;

ORCID: 0000-0002-0759-3107;
eLibrary SPIN: 1802-3224;
e-mail: geor_gabaraev1@mail.ru

* Автор, ответственный за переписку / Corresponding author

DOI: <https://doi.org/10.17816/DD569388>

Вклад систем искусственного интеллекта в улучшение выявления аневризм аорты по данным компьютерной томографии грудной клетки

А.В. Соловьёв^{1,2}, Ю.А. Васильев¹, В.Е. Сеницын^{1,3,4}, А.В. Петрайкин¹,
А.В. Владзимирский¹, И.М. Шулькин¹, Д.Е. Шарова¹, Д.С. Семенов¹

¹ Научно-практический клинический центр диагностики и телемедицинских технологий, Москва, Россия;

² Морозовская детская городская клиническая больница, Москва, Россия;

³ Городская клиническая больница имени И.В. Давыдовского, Москва, Россия;

⁴ Московский государственный университет имени М.В. Ломоносова, Москва, Россия

АННОТАЦИЯ

Обоснование. Аневризмы аорты — «тихие убийцы», развиваются без симптомов и могут привести к летальному исходу. Ежегодно заболеваемость аневризмой грудной аорты составляет около 10 случаев на 100 000 человек, а частота разрывов аневризм — около 1,6 случая. Ранняя диагностика и лечение могут спасти жизнь пациента. Использование технологий искусственного интеллекта может значительно улучшить качество диагностики и предотвратить летальный исход. **Цель** — оценить эффективность применения технологий искусственного интеллекта в выявлении аневризм грудного отдела аорты на компьютерной томографии органов грудной клетки и исследовать возможности использования этих технологий в качестве системы поддержки принятия врачебных решений врача-рентгенолога при первичном описании лучевых исследований.

Материалы и методы. Были оценены результаты использования технологий искусственного интеллекта для выявления аневризмы грудной аорты на компьютерной томографии органов грудной клетки без контрастного усиления. Была сформирована выборка из 84 405 случаев обследования пациентов старше 18 лет, из которых отобрано и ретроспективно пересмотрено сосудистыми хирургами Научно-исследовательского института скорой помощи имени Н.В. Склифосовского 86 исследований с подозрением на наличие аневризмы грудного отдела аорты по данным технологий искусственного интеллекта. Эти исследования были также ретроспективно оценены двумя врачами-рентгенологами. Была сформирована дополнительная выборка из 968 исследований, взятых в случайном порядке из общего числа, для оценки корреляции возраста пациентов и диаметра грудного отдела аорты.

Результаты. Анализ показал, что в 44 исследованиях аневризма была первично выявлена врачом-рентгенологом, в 31 случае аневризмы не были описаны, но технология искусственного интеллекта помогла выявить патологию. Ещё 6 исследований были исключены из выборки, а в 5 случаях были обнаружены ложноположительные результаты анализа. Использование технологий искусственного интеллекта обнаруживает и выделяет патологические изменения аорты на медицинских изображениях, тем самым повышая выявляемость аневризмы грудной аорты при интерпретации результатов компьютерной томографии органов грудной клетки на 41%. При первичном описании лучевых исследований и в ретроспективных исследованиях целесообразно использовать технологии искусственного интеллекта для профилактики пропусков клинически значимых патологий — как в качестве системы поддержки принятия врачебных решений для врача-рентгенолога, так и для повышения выявляемости патологического расширения грудного отдела аорты. По дополнительной выборке в популяции взрослого населения частота дилатации грудного отдела аорты составила 14,5%, а аневризм грудного отдела аорты — 1,2%. Данные также показали возрастную зависимость диаметра грудного отдела аорты для мужчин и женщин.

Заключение. Применение технологий искусственного интеллекта в процессе первичного описания результатов компьютерной томографии органов грудной клетки может повысить выявляемость клинически значимых патологических состояний, таких как аневризма грудного отдела аорты. Расширение ретроспективного скрининга по данным компьютерной томографии органов грудной клетки с использованием технологий искусственного интеллекта может улучшить качество диагностики сопутствующих патологий и предотвратить негативные последствия для пациентов.

Ключевые слова: компьютерная томография; аневризма аорты; искусственный интеллект.

Как цитировать:

Соловьёв А.В., Васильев Ю.А., Сеницын В.Е., Петрайкин А.В., Владзимирский А.В., Шулькин И.М., Шарова Д.Е., Семенов Д.С. Вклад систем искусственного интеллекта в улучшение выявления аневризм аорты по данным компьютерной томографии грудной клетки // Digital Diagnostics. 2024. Т. 5, № 1. С. 29–40. DOI: <https://doi.org/10.17816/DD569388>

Рукопись получена: 19.09.2023

Рукопись одобрена: 19.12.2023

Опубликована online: 11.03.2024

DOI: <https://doi.org/10.17816/DD569388>

Improving aortic aneurysm detection with artificial intelligence based on chest computed tomography data

Alexander V. Solovet^{1,2}, Yuriy A. Vasilev¹, Valentin E. Sinitsyn^{1,3,4}, Alexey V. Petraikin¹, Anton V. Vladzmyrskyy¹, Igor M. Shulkin¹, Daria E. Sharova¹, Dmitry S. Semenov¹

¹ Research and Practical Clinical Center for Diagnostics and Telemedicine Technologies, Moscow, Russia;

² Morozov Children's Municipal Clinical Hospital, Moscow, Russia;

³ Clinical City Hospital named after I.V. Davydovsky, Moscow, Russia;

⁴ Lomonosov Moscow State University, Moscow, Russia

ABSTRACT

BACKGROUND: Aortic aneurysms are known as “silent killers” because this potentially fatal condition can be asymptomatic. The annual incidence of thoracic aortic aneurysms and ruptures is approximately 10 and 1.6 per 100,000 individuals, respectively. The mortality rate for ruptured aneurysms ranges from 94% to 100%. Early diagnosis and treatment can be life-saving. Artificial intelligence technologies can significantly improve diagnostic accuracy and save the lives of patients with thoracic aortic aneurysms.

AIM: This study aimed to assess the efficacy of artificial intelligence technologies for detecting thoracic aortic aneurysms on chest computed tomography scans, as well as the possibility of using artificial intelligence as a clinical decision support system for radiologists during the primary interpretation of radiological images.

MATERIALS AND METHODS: The results of using artificial intelligence technologies for detecting thoracic aortic aneurysms on non-contrast chest computed tomography scans were evaluated. A sample of 84,405 patients >18 years old was generated, with 86 cases of suspected thoracic aortic aneurysms based on artificial intelligence data selected and retrospectively assessed by radiologists and vascular surgeons. To assess the age distribution of the aortic diameter, an additional sample of 968 cases was randomly selected from the total number.

RESULTS: In 44 cases, aneurysms were initially identified by radiologists, whereas in 31 cases, aneurysms were not detected initially; however, artificial intelligence aided in their detection. Six studies were excluded, and five studies had false-positive results. Artificial intelligence aids in detecting and highlighting aortic pathological changes in medical images, increasing the detection rate of thoracic aortic aneurysms by 41% when interpreting chest computed tomography scans. The use of artificial intelligence technologies for primary interpretations of radiological studies and retrospective assessments is advisable to prevent underdiagnosis of clinically significant pathologies and improve the detection rate of pathological aortic enlargement. In the additional sample, the incidence of thoracic aortic dilation and thoracic aortic aneurysms in adults was 14.5% and 1.2%, respectively. The findings also revealed an age-dependent diameter of the thoracic aorta in both men and women.

CONCLUSION: The use of artificial intelligence technologies in the primary interpretation of chest computed tomography scans can improve the detection rate of clinically significant pathologies such as thoracic aortic aneurysms. Expanding retrospective screening based on chest computed tomography scans using artificial intelligence can improve the diagnosis of concomitant pathologies and prevent negative consequences.

Keywords: computed tomography; aortic aneurysm; artificial intelligence.

To cite this article:

Solovet AV, Vasilev YuA, Sinitsyn VE, Petraikin AV, Vladzmyrskyy AV, Shulkin IM, Sharova DE, Semenov DS. Improving aortic aneurysm detection with artificial intelligence based on chest computed tomography data. *Digital Diagnostics*. 2024;5(1):29–40. DOI: <https://doi.org/10.17816/DD569388>

DOI: <https://doi.org/10.17816/DD569388>

人工智能系统对从胸部计算机断层扫描数据中改进主动脉瘤检测的贡献

Alexander V. Solovev^{1,2}, Yuriy A. Vasilev¹, Valentin E. Sinitsyn^{1,3,4}, Alexey V. Petraikin¹, Anton V. Vladzmyrskyy¹, Igor M. Shulkin¹, Daria E. Sharova¹, Dmitry S. Semenov¹

¹ Research and Practical Clinical Center for Diagnostics and Telemedicine Technologies, Moscow, Russia;

² Morozov Children's Municipal Clinical Hospital, Moscow, Russia;

³ Clinical City Hospital named after I.V. Davydovsky, Moscow, Russia;

⁴ Lomonosov Moscow State University, Moscow, Russia

摘要

论证。主动脉瘤是“无声杀手”，发病时没有任何症状，而且可能致命。胸主动脉瘤的年发病率约为每10万人10例，动脉瘤破裂的发病率约为1.6例。早期诊断和治疗可以挽救患者的生命。人工智能技术的使用可以大大提高诊断质量，防止死亡。

目的。本研究的目的是评估人工智能技术在胸部计算机断层扫描中检测胸主动脉瘤的有效性，并探讨这些技术作为放射科医生临床决策支持系统在放射学检查初步描述中的可行性。

材料与方法。对使用人工智能技术在无对比度增强的胸部计算机断层扫描中检测胸主动脉瘤的结果进行了评估。研究人员对84405名18岁以上的患者进行了抽样检查。通过人工智能技术筛选出86个疑似胸主动脉瘤的检查。俄罗斯N. V. 斯克利福索夫斯基急救研究所的血管外科医生对这些检查结果进行了回顾性分析。两名放射科医生也对这些检查进行了回顾性评估。另外从总数中随机抽取，形成了包括968个检查在内的额外样本以评估患者年龄与胸主动脉直径之间的相关性。

结果。分析表明，在44例检查中，动脉瘤最初是由放射科医生检测到的；在31例检查中，动脉瘤未被描述，但人工智能技术帮助确定了病理。另有6例检查被排除在样本之外，而有5例检查发现了假阳性检测结果。

使用人工智能技术可以检测并突出显示医学图像中主动脉的病理变化。因此，在解读胸部计算机断层扫描结果时发现胸主动脉瘤的概率提高了41%。在放射学研究的初步描述和回顾性研究中，使用人工智能技术来防止遗漏具有临床意义的病理是可行的，既可作为放射科医生的医疗决策支持系统，又可提高胸主动脉病理扩张的可探测性。

在另一个成年人群样本中，胸主动脉扩张的发生率为14.5%，胸主动脉瘤的发生率为1.2%。数据还显示了，男性和女性的胸主动脉直径与年龄有关。

结论。将人工智能技术应用于胸部器官CT结果的初步描述过程中，可以提高对胸主动脉瘤等临床重大病理状态的检测。利用人工智能技术扩大胸部计算机断层扫描的回顾性筛查范围，可提高合并症的诊断质量，避免给患者带来不良后果。

关键词：电子计算机断层扫描；主动脉瘤；人工智能。

引用本文：

Solovev AV, Vasilev YuA, Sinitsyn VE, Petraikin AV, Vladzmyrskyy AV, Shulkin IM, Sharova DE, Semenov DS. 人工智能系统对从胸部计算机断层扫描数据中改进主动脉瘤检测的贡献. *Digital Diagnostics*. 2024;5(1):29–40. DOI: <https://doi.org/10.17816/DD569388>

收到: 19.09.2023

接受: 19.12.2023

发布日期: 11.03.2024

ОБОСНОВАНИЕ

По данным Всемирной организации здравоохранения, одна из основных причин смертности — сердечно-сосудистые заболевания и связанные с ними патологии [1]. К ним относятся аневризмы аорты, известные как «тихие убийцы». Они обычно формируются бессимптомно и могут привести к расслоению или разрыву сосуда, что в 94–100% случаев становится причиной смерти пациента [2, 3]. Существует очень небольшое количество работ, относящихся к статистическому анализу распространённости аневризм грудной аорты [4]. В России, по различным данным, частота встречаемости аневризмы восходящего отдела аорты составляет 0,16–1,06%. Важно отметить, что в России крупное эпидемиологическое исследование по встречаемости аневризм грудного отдела аорты последний раз проводилось около 40 лет назад [5], что подтверждает актуальность проведения новых исследований.

По данным аутопсий, которые проводили в течение десяти лет в 15-й городской клинической больнице имени О.М. Филатова (г. Москва), причина смерти в результате аневризмы грудного отдела аорты была подтверждена в 0,8% случаев, из которых только в 11% было подозрение о наличии аневризмы до наступления смерти пациента [4]. В США аневризма аорты занимает 17-е место в структуре смертности от сердечно-сосудистых заболеваний. В год заболеваемость аневризмами грудной аорты в США составляет около 10 случаев на 100 000 человек, а частота разрывов аневризмы — около 1,6 случая на 100 000 человек [6]. В Швеции встречаемость аневризм и расслоений грудного отдела аорты составляет до 16,3 случая на 100 000 человек [7]. По данным Йельского университета, годовая частота разрывов аневризмы составляет до 3,6%, а частота расслоения — до 3,7% среди зарегистрированных случаев [8].

При проведении скрининга злокачественных новообразований лёгких с помощью компьютерной томографии (КТ) органов грудной клетки (ОГК) патологическое расширение грудной аорты обнаруживается у пациентов старше 50 лет с частотой до 8,1% [9, 10].

Оппортунистический скрининг — метод проспективного и ретроспективного анализа целевых исследований, который выявляет дополнительную патологию и факторы риска, помимо целевой. Такой подход позволяет избежать повторного проведения исследований, что способствует уменьшению лучевой нагрузки на пациента [11].

За 2022 год в Москве было проведено более 584 000 КТ-исследований ОГК без применения контрастного вещества. Данный объём исследований представляет потенциал для оппортунистического выявления различных патологических состояний, включая расширение грудной аорты (дилатацию, аневризму) — жизнеугрожающую патологию [12].

В Москве с 2020 года проводится крупнейшее в мире исследование для оценки эффективности и качества

применения технологий искусственного интеллекта (ТИИ) — «Эксперимент по использованию инновационных технологий в области компьютерного зрения для анализа медицинских изображений и дальнейшего применения в системе здравоохранения города Москвы» (далее — Московский Эксперимент) [13]. В рамках Московского Эксперимента ТИИ используют в тестовом режиме под контролем экспертов Государственного бюджетного учреждения «Научно-практический клинический центр диагностики и телемедицинских технологий» Департамента здравоохранения города Москвы. Процесс включает постоянную оценку качества работы системы и корректировку её функционирования, проводятся вычисления метрик точности, выявляются ошибки срабатывания и другие характеристики. В результате создаются условия для проведения ретроспективных исследований, а также обработки лучевых данных при первичном анализе врачом-рентгенологом.

ЦЕЛЬ

Оценить эффективность применения ТИИ в выявлении аневризм грудного отдела аорты по данным КТ ОГК и проанализировать возможности использования ТИИ в качестве системы поддержки принятия врачебных решений для врача-рентгенолога при первичном описании лучевых исследований.

МАТЕРИАЛ И МЕТОДЫ

Дизайн исследования

Выполнен ретроспективный анализ 84 405 результатов КТ ОГК из Единого радиологического информационного сервиса автоматизированной Единой медицинской информационной системы города Москвы «Единая медицинская информационно-аналитическая система» (ЕРИС ЕМИАС) за период с 01.06.2022 по 30.11.2022, обработанных ТИИ. Дизайн исследования представлен на рис. 1. Из общей выборки 84 405 пациентов старше 18 лет с использованием данных ТИИ было отобрано 86 исследований с подозрением на аневризму грудного отдела аорты максимальным диаметром более 50 мм (отбор проводили сосудистые хирурги Государственного учреждения здравоохранения города Москвы «Научно-исследовательский институт скорой помощи имени Н.В. Склифосовского»).

Далее полученная выборка была перепроверена двумя врачами-рентгенологами (из Научно-практического клинического центра диагностики и телемедицинских технологий) со стажем более 5 лет. В случае расхождения мнений первых двух рентгенологов, эксперт с 10-летним стажем врача-рентгенолога выступал в роли арбитра, принимая окончательное решение относительно наличия аневризмы и формулировки её описания.

В процессе пересмотра исключили 11 пациентов: 6 — из-за отсутствия первичного протокола




Рис. 1. Дизайн выполненного исследования. КТ — компьютерная томография; ЕРИС — Единый радиологический информационный сервис; ИИ — искусственный интеллект.

от врача-рентгенолога в ЕРИС, 5 — из-за того, что в результате обработки данных ТИИ (оценка нецелевой патологии или органа) исследования были классифицированы как ложноположительные. Итоговая выборка составила 75 пациентов, направленных на дообследование и лечение.

Дополнительно из 84 405 исследований для оценки возрастного распределения диаметра аорты было случайным образом отобрано 1000 исследований. После исключения 32 случаев ввиду отсутствия данных о возрасте пациентов, объём данной выборки составил 968 исследований (433 мужчины и 535 женщин — 44,7% и 55,3% соответственно).

Критерии включения

Критерии включения КТ-исследований ОГК в выборку для анализа с помощью ТИИ в рамках Московского Эксперимента по направлению «Аневризма грудного отдела аорты»:

- пациенты (женщины и мужчины) амбулаторных и стационарных медицинских учреждений Департамента здравоохранения города Москвы (возраст — старше 18 лет);
- проведённые исследования: КТ ОГК без контрастного усиления с толщиной среза ≤ 3 мм;
- наличие КТ-изображений ОГК в формате DICOM и протокола врача-рентгенолога в ЕРИС ЕМИАС.

Критерии исключения:

- пациенты с наличием металлоконструкций (постоперационные скобы, пластины), формирующих артефакты в области ОГК, включая кардиостимуляторы;

- наличие контрастного усиления и исследования с лёгочным кернелем;
- отсутствие КТ-изображений в формате DICOM и/или протокола врача-рентгенолога в ЕРИС ЕМИАС.

Условия проведения

ТИИ обрабатывали исследования для определения патологического расширения грудного отдела аорты по правилам, которые называются «базовые диагностические требования». Данные правила были разработаны на основании рекомендаций Европейского общества кардиологов по диагностике и лечению заболеваний аорты [14]:

- дилатация восходящей аорты — от 40 до 49 мм;
- аневризма восходящей аорты — ≥ 50 мм;
- аневризма нисходящей аорты — ≥ 40 мм [15].

Для автоматического определения диаметра грудного отдела аорты был применён отечественный алгоритм ТИИ «Chest-IRA» (IRA Labs, Россия). В рамках Московского Эксперимента была оценена точность работы данной ТИИ, которая показала следующие результаты:

- площадь под ROC-кривой (AUC) — 0,99;
- чувствительность — 0,94;
- специфичность — 0,96;
- точность — 0,95;
- длительность анализа (одного исследования) — 2,1 мин [16].

Пример работы алгоритма с ТИИ представлен на рис. 2. Ретроспективная верификация КТ-исследований с подозрением на наличие аневризм грудного отдела аорты для выборки из всех 75 исследований (максимальный диаметр — более 50 мм) проводилась двумя

врачами-рентгенологами (с опытом работы более 5 лет), одним экспертом врачом-рентгенологом и сосудистыми хирургами (с опытом работы более 10 лет). Проверена корректность работы ТИИ по измерениям грудного отдела аорты в аксиальной проекции. Врачи выполняли измерения как максимального переднезаднего диаметра, так и перпендикулярного диаметра грудного отдела аорты, придерживаясь рекомендаций рабочей группы Европейской ассоциации по сердечно-сосудистой визуализации и Европейского общества кардиологов [17]. Все пациенты из выборки направлялись на дообследование, где принимались решения о дальнейшем наблюдении или лечении.

Анализ нормальности распределения в группах пациентов проводился согласно критерию Шапиро–Уилка. С учётом отличия распределения от нормальных величин ($p < 0,001$) для всех подвыборок данные представлены в виде: «медиана [25-й процентиль; 75-й процентиль]; минимальное–максимальное значение величины». Межгрупповые сравнения проводили методом Манна–Уитни.

РЕЗУЛЬТАТЫ

Основные результаты исследования

С помощью алгоритма ТИИ было обработано 84 405 КТ-исследований ОГК без контрастного усиления для выявления патологического расширения грудного отдела аорты. Из данной выборки было отобрано 86 исследований (62 мужчины, 24 женщины) с подозрением на наличие аневризмы грудной аорты по данным ТИИ, которые ретроспективно были оценены врачами-рентгенологами и сосудистыми хирургами. Из 86 исследований 6 были исключены из выборки по причине отсутствия первичного протокола врача-рентгенолога в ЕРИС ЕМИАС; 5 были

ложноположительными по результатам обработки ТИИ (оценка нецелевой патологии/органа, см. рис. 2, *b*) — они также были исключены из выборки.

В итоговую выборку вошло 75 исследований: 57 мужчин (66 [59; 73]; 27–87 лет) и 18 женщин (62 [59; 74]; 47–87 лет). Аневризма грудного отдела аорты была описана в первичном протоколе рентгенологического исследования в 44 случаях (59%), а в 31 случае (41%) в первичном протоколе аневризмы отмечено не было. Таким образом, применение ТИИ позволило дополнительно выявить 31 случай аневризмы грудного отдела аорты (41%). Среди данной группы пациентов максимальный диаметр грудного отдела аорты составил 56 [54; 60]; 52–84 мм — у мужчин, и 57 [54; 63]; 52–87 мм — у женщин.

Пациенты с аневризмой аорты, выявленной с помощью ТИИ на исследованиях ОГК методом КТ, были проинформированы и направлены на уточняющие исследования (эхокардиографию, КТ или магнитно-резонансную ангиографию, консультацию кардиолога и/или сосудистого хирурга) с целью определения тактики их ведения и лечения.

В ходе дообследования была получена дополнительная информация: из 75 пациентов четверо (5,33%) пациентов скончались до завершения диагностического процесса или оперативного вмешательства, а трое (4%) пациентов приняли решение отказаться от дальнейшего диагностического обследования и лечения. Ещё 31 (41,33%) пациент отказался от общения.

Из 37 пациентов, которые остались под наблюдением и продолжили лечение, у 25 (33,33%) после комплексного диагностического обследования был подтверждён диагноз аневризмы грудного отдела аорты (они продолжают находиться под наблюдением), а у 12 (16%) диагностика позволила уточнить диагноз (они продолжают лечение у кардиолога). У 3 пациентов после




Рис. 2. Пример работы комплексного сервиса с искусственным интеллектом в обработке данных компьютерной томографии отдела грудной клетки: *a* — технология искусственного интеллекта корректно выделила и маркировала (красная линия) подозрение на наличие аневризмы грудной аорты восходящего и нисходящего отделов; *b* — ложноположительный результат: размечено (красная линия) образование средостения вместе с восходящим отделом грудной аорты, в зелёной рамке указан диаметр нисходящего отдела грудной аорты. У данного комплексного сервиса с искусственным интеллектом есть дополнительные модули, маркирующие инфильтративные изменения лёгких (оранжевый контур) и плевральный выпот (жёлтый контур).

диагностического обследования наличие аневризмы не подтвердилось: у них была диагностирована дилатация грудного отдела аорты. Кроме того, было выполнено 2 хирургических вмешательства по стентированию аорты из-за аневризмы.

Группы мужчин и женщин с выявленными с помощью ТИИ аневризмами по возрасту и по максимальному диаметру грудного отдела достоверно не различаются ($p > 0,05$).

Результаты второй части исследования

Нами были получены также предварительные данные по встречаемости аневризм в выборке из 968 исследований (рис. 3), взятых в случайном порядке из 84 405 случаев. В популяции взрослого населения (от 18 лет) частота встречаемости дилатации грудного отдела аорты составила 14,5%, а аневризм грудного отдела аорты — 1,2%.

Для данной группы возраст пациентов составил: для женщин ($n=535$) — 65 [51; 75]; 19–102 лет, для мужчин ($n=433$) — 60 [47; 71]; 18–95 лет. Выборка женщин несколько больше, чем мужчин, что отражает распределение по полу в общей совокупности обследованных пациентов. Медиана возраста у женщин (65 лет) несколько выше, чем у мужчин (60 лет), интерквартильные размахи схожи.

Для данной группы диаметр грудного отдела аорты пациентов составил: у женщин — 34 [31; 37]; 20–50 мм, у мужчин — 36 [33; 39]; 24–60 мм.

Отмечены достоверные различия ($p < 0,001$) между группами мужчин и женщин по возрасту и по максимальному диаметру грудного отдела аорты.

Следует отметить выраженную возрастную зависимость диаметра грудного отдела аорты для мужчин и женщин. Для мужчин относительные возрастные изменения

диаметра грудного отдела аорты более выражены и составляют 0,177 мм/год, для женщин — 0,118 мм/год.

ОБСУЖДЕНИЕ

Резюме результата исследования

Анализ полученных в ходе работы данных показал, что в выборке пациентов с аневризмами аорты (75 пациентов) группы мужчин и женщин достоверно не различаются ($p > 0,05$), как по возрасту, так и по максимальному диаметру грудного отдела аорты. В то же время в выборке из 968 пациентов (случайно взятых из общей совокупности) у мужчин и женщин по возрасту и по максимальному диаметру грудного отдела аорты отмечены достоверные различия ($p < 0,001$). Это обосновывает необходимость в разработке половозрастных нормативов для описания возрастного распределения. Для более полного анализа выявленных закономерностей требуется дополнительное, специально спланированное исследование.

Обсуждение результата исследования

Увеличение числа выявленных аневризм за счёт применения алгоритма ТИИ в ретроспективном исследовании подтверждает эффективность и целесообразность использования данного решения на практике — например, в качестве вспомогательного инструмента врача-рентгенолога при первичном описании лучевых исследований. Однако отмечено присутствие ложноположительных результатов работы программного обеспечения. Существуют способы минимизации таких ошибок за счёт мониторингов и дообучения алгоритма [20–22].

По данным литературы, существует положительная корреляция между возрастом и диаметром грудного отдела аорты. Отмечается, что у лиц мужского пола имеются более




Рис. 3. График зависимости максимального диаметра грудного отдела аорты от возраста для выборки из 968 исследований: а — у мужчин; б — у женщин.

высокие, по сравнению с женщинами, значения диаметра грудного отдела аорты [18], а также более выраженная его зависимость от возраста [19], что полностью соответствует статистическим результатам, полученным в нашей работе.

Отмечен риск пропуска врачами клинически значимых патологий по разным причинам: профессиональное выгорание (например, после пандемии COVID-19), увеличение рабочей нагрузки, нехватка медицинского персонала. Это ещё один довод в пользу использования ТИИ в качестве системы поддержки принятия врачебных решений для врача-рентгенолога при анализе результатов КТ ОГК, потому что применение ТИИ может способствовать повышению выявляемости и сокращению числа пропусков клинически значимых патологий [23].

Использованная нами отечественная ТИИ не является единственной в мире, и при выборе ТИИ можно ориентироваться на метрики качества. Имеются также зарубежные аналоги ТИИ для автоматического измерения диаметра грудного отдела аорты и определения аневризм, которые помогают избежать ошибок и могут быть использованы в оппортунистическом скрининге [24, 25].

По данным литературы, ТИИ помогают врачам-рентгенологам сократить время, затраченное на выявление патологий в лучевых исследованиях [26, 27].

ТИИ — перспективный инструмент для измерений аорты [28]. Однако вопрос точности измерений ещё открыт и требует дополнительного исследования. Данное исследование показывает, что ТИИ не могут служить заменой врачам, но могут помогать врачу-рентгенологу, сообщая ему о возможной патологии аорты для исключения пропусков клинически значимых аномалий. При этом отмечается, что врачу-рентгенологу важно знать о принципе работы ТИИ и о возможных ошибках при анализе исследований [29–33]. Таким образом, применение ТИИ в медицине может быть важным инструментом в выявлении аневризмы грудного отдела аорты.

ТИИ целесообразно применять для поиска патологических расширений грудного отдела аорты как при первичном описании лучевых исследований, так и при ретроспективных исследованиях с целью минимизации возможных пропусков клинически значимых изменений.

ЗАКЛЮЧЕНИЕ

Применение ТИИ в процессе первичного описания КТ ОГК и расширение оппортунистического скрининга может увеличить выявляемость клинически значимых патологических состояний, таких как аневризма грудного отдела аорты, и предотвратить негативные последствия для пациентов. Дальнейшая оптимизация маршрутизации данной категории пациентов, требующих срочного медицинского вмешательства для оперативного лечения, является актуальной задачей. Целесообразна разработка популяционных нормативных значений диаметра грудной аорты, что позволит скорректировать критерии диагностики данной патологии.

ДОПОЛНИТЕЛЬНАЯ ИНФОРМАЦИЯ

Источник финансирования. Данная статья подготовлена авторским коллективом в рамках научно-исследовательской работы «Оппортунистический скрининг социально значимых и иных распространённых заболеваний» (№ в Единой государственной информационной системе учёта: № 123031400009-1) в соответствии с приказом Департамента здравоохранения города Москвы от 21.12.2022 № 1196 «Об утверждении государственных заданий, финансовое обеспечение которых осуществляется за счёт средств бюджета города Москвы государственным бюджетным (автономным) учреждениям подведомственным Департаменту здравоохранения города Москвы, на 2023 год и плановый период 2024 и 2025 годов».

Конфликт интересов. Авторы заявляют об отсутствии явных и потенциальных конфликтов интересов, связанных с публикацией настоящей статьи.

Вклад авторов. Все авторы подтверждают соответствие своего авторства международным критериям ICMJE (все авторы внесли вклад в разработку концепции, проведение поисково-аналитической работы и подготовку статьи, прочли и одобрили финальную версию перед публикацией). Наибольший вклад распределён следующим образом: А.В. Соловьёв — концепция и дизайн исследования, написание текста статьи, редактирование и утверждение итогового варианта текста рукописи; Ю.А. Васильев, В.Е. Сеницын — концепция исследования, финальная вычитка текста; А.В. Петрайкин, А.В. Владимировский — концепция и дизайн исследования, написание и редактирование текста; И.М. Шулькин, Д.Е. Шарова, Д.С. Семенов — концепция, редактирование и утверждение итогового варианта текста рукописи, консультативная поддержка.

ADDITIONAL INFORMATION

Funding source. This article was prepared by the team of authors within the framework of the research work "Opportunistic screening of socially significant and other common diseases" (№ in the Unified State Information System of Accounting: № 123031400009-1) in accordance with the order of the Department of Health of Moscow from 21.12.2022 № 1196 "On approval of state tasks, the financial support of which is carried out at the expense of the budget of the city of Moscow state budgetary (autonomous) institutions subordinate to the Department of Health Protection of Moscow, for years 2023, 2024 and 2025".

Competing interests. The authors declare that they have no competing interests.

Authors' contribution. All authors made a substantial contribution to the conception of the work, acquisition, analysis, interpretation of data for the work, drafting and revising the work, final approval of the version to be published and agree to be accountable for all aspects of the work. The major contributions are distributed as follows: A.V. Solovov — research conception and design, article writing, editing, and approval of the final manuscript; Yu.A. Vasilev, V.E. Sinitsyn — research conception, final proofreading of the text; A.V. Petraikin, A.V. Vladymyrsky — research conception and design, writing, and editing of the text; I.M. Shulkin, D.E. Sharova, D.S. Semenov — research conception, editing, and approval of the final manuscript, advisory support.

СПИСОК ЛИТЕРАТУРЫ

1. 10 ведущих причин смерти в мире [Internet]. Всемирная организация здравоохранения. [дата обращения: 12.05.2023]. Доступ по ссылке: <https://www.who.int/ru/news-room/fact-sheets/detail/the-top-10-causes-of-death>
2. Gouveia e Melo R., Silva Duarte G., Lopes A., et al. Incidence and Prevalence of Thoracic Aortic Aneurysms: A Systematic Review and Meta-analysis of Population-Based Studies // *Seminars in thoracic and cardiovascular surgery*. 2022. Vol. 34, N 1. P. 1–16. doi: 10.1053/j.semtcvs.2021.02.029
3. Клинические рекомендации. Рекомендации по диагностике и лечению заболеваний аорты (2017) // *Кардиология и сердечно-сосудистая хирургия*. 2018. Т. 11, № 1. С. 7–67. EDN: YPAKRP
4. Кузнецовский Ф.В., Осипов А.Х., Евсиков Е.М., Абрамов И.С., Отарова С.М. Распространенность и природа аневризм и расслоений аорты по данным анализа последовательных патологоанатомических вскрытий в течение десяти лет в ГКБ № 15 им. О.М. Филатова // *Российский кардиологический журнал*. 2004. Т. 9, № 6. С. 5–13. EDN: ISVRYL
5. Иртюга О.Б., Воронкина И.В., Смагина Л.В., и др. Частота выявления аневризмы восходящего отдела аорты и механизм ее развития по данным регистра ФГУ ФЦСКЭ им В.А. Алмазова // *Бюллетень Федерального Центра сердца, крови и эндокринологии им. В.А. Алмазова*. 2011. № 5. С. 73–78. EDN: OWGHOB
6. Lavall D., Schäfers H.J., Böhm M., Laufs U. Aneurysms of the ascending aorta // *Deutsches Arzteblatt international*. 2012. Vol. 109, N 13. P. 227–233. doi: 10.3238/arztebl.2012.0227
7. Olsson C., Thelin S., Ståhle E., Ekbom A., Granath F. Thoracic Aortic Aneurysm and Dissection // *Circulation*. 2006. Vol. 114, N 24. P. 2611–2618. doi: 10.1161/CIRCULATIONAHA.106.630400
8. Elefteriades J.A. Natural history of thoracic aortic aneurysms: indications for surgery, and surgical versus nonsurgical risks // *The Annals of thoracic surgery*. 2002. Vol. 74, N 5. P. 1877–1880. doi: 10.1016/s0003-4975(02)04147-4
9. Tsai E.B., Chiles C., Carter B.W., et al. Incidental Findings on Lung Cancer Screening: Significance and Management // *Seminars in ultrasound, CT, and MR*. 2018. Vol. 39, N 3. P. 273–281. doi: 10.1053/j.sult.2018.02.005
10. Чернина В.Ю., Блохин И.А., Николаев А.Е., и др. Тактика ведения инциденталом. Раздел 3. Щитовидная железа, гипофиз, сосуды и средостение. Москва : Государственное бюджетное учреждение здравоохранения города Москвы «Научно-практический клинический центр диагностики и телемедицинских технологий Департамента здравоохранения города Москвы», 2019. EDN: WSYSYP
11. Law M. "Opportunistic" Screening // *J Med Screen*. 1994. Vol. 1, N 4. P. 208. doi: 10.1177/096914139400100403
12. Kumar Y., Hooda K., Li S., et al. Abdominal aortic aneurysm: pictorial review of common appearances and complications // *Annals of translational medicine*. 2017. Vol. 5, N 12. P. 256. doi: 10.21037/atm.2017.04.32
13. Компьютерное зрение в лучевой диагностике: первый этап Московского эксперимента / под ред. Ю.А. Васильева, А.В. Владимировского. Москва : Общество с ограниченной ответственностью «Издательские решения», 2022. EDN: FOYLXK
14. Erbel R., Aboyans V., Boileau C., Vlachopoulos C. 2014 ESC Guidelines on the diagnosis and treatment of aortic diseases: Document covering acute and chronic aortic diseases of the thoracic and abdominal aorta of the adult. The Task Force for the Diagnosis and Treatment of Aortic Diseases of the European // *European heart journal*. 2014. Vol. 35, N 41. P. 2873–2926. doi: 10.1093/eurheartj/ehu281
15. Документы по Эксперименту [Internet]. Центр диагностики и телемедицины. [дата обращения: 16.06.2023]. Доступ по ссылке: <https://mosmed.ai/ai/docs/>
16. Chest-IRA [Internet]. Центр диагностики и телемедицины. [дата обращения: 16.06.2023]. Доступ по ссылке: https://mosmed.ai/service_catalog/chestira/
17. Evangelista A., Sitges M., Jondeau G., et al. Multimodality imaging in thoracic aortic diseases: a clinical consensus statement from the European Association of Cardiovascular Imaging and the European Society of Cardiology working group on aorta and peripheral vascular diseases // *European Heart Journal Cardiovascular Imaging*. 2023. Vol. 24, N 5. P. e65–e85. doi: 10.1093/ehjci/jead024
18. Etli M., Avnioglu S., Yilmaz H., Karahan O. Investigation of the correlation between cardiac parameters and aortic diameter in patients with ascending aortic aneurysm // *Egyptian Heart Journal*. 2022. Vol. 74, N 1. P. 1–7. doi: 10.1186/s43044-022-00238-0
19. Pearce W., Slaughter M., Lemaire S., et al. Aortic diameter as a function of age, gender, and body surface area // *Surgery*. 1993. Vol. 114, N 4. P. 691–697.
20. Васильев Ю.А., Бобровская Т.М., Арзамасов К.М., и др. Основополагающие принципы стандартизации и систематизации информации о наборах данных для машинного обучения в медицинской диагностике // *Менеджер здравоохранения*. 2023. Т. 4. С. 28–41. EDN: EPGAMD doi: 10.21045/1811-0185-2023-4-28-41
21. Четвериков С.Ф., Арзамасов К.М., Андрейченко А.Е., и др. Подходы к формированию выборки для контроля качества работы систем искусственного интеллекта в медико-биологических исследованиях // *Современные технологии в медицине*. 2023. Т. 15, № 2. С. 19–25. EDN: FUKXYC doi: 10.17691/stm2023.15.2.02
22. Зинченко В.В., Арзамасов К.М., Четвериков С.Ф., и др. Методология проведения пострегистрационного клинического мониторинга для программного обеспечения с применением технологий искусственного интеллекта // *Современные технологии в медицине*. 2022. Т. 14, № 5. С. 15–25. doi: 10.17691/stm2022.14.5.02
23. Chernina V.Y., Belyaev M.G., Silin A.Y., et al. A diagnostic and economic evaluation of the complex artificial intelligence algorithm aimed to detect 10 pathologies on the chest CT images // *medRxiv*. 2023. Vol. 4. doi: 10.1101/2023.04.19.23288584
24. Macruz F.B.C., Lu C., Strout J., et al. Quantification of the Thoracic Aorta and Detection of Aneurysm at CT: Development and Validation of a Fully Automatic Methodology // *Radiology: Artificial Intelligence*. 2022. Vol. 4, N 2. P. e210076. doi: 10.1148/ryai.210076
25. Adam C., Fabre D., Mougin J., et al. Pre-surgical and Post-surgical Aortic Aneurysm Maximum Diameter Measurement: Full Automation by Artificial Intelligence // *European Journal of Vascular and Endovascular Surgery*. 2021. Vol. 62, N 6. P. 869–877. doi: 10.1016/j.ejvs.2021.07.013
26. Владимировский А.В., Кудрявцев Н.Д., Кожихина Д.Д., и др. Эффективность применения технологий искусственного интел-

лекта для двойных описаний результатов профилактических исследований легких // Профилактическая медицина. 2022. Vol. 25, N 7. P. 7–15. doi: 10.17116/profmed202250717

27. Rodriguez-Ruiz A., Lång K., Gubern-Merida A., et al. Stand-Alone Artificial Intelligence for Breast Cancer Detection in Mammography: Comparison With 101 Radiologists // Journal of the National Cancer Institute. 2019. Vol. 111, N 9. P. 916–922. doi: 10.1093/jnci/djy222

28. Rueckel J., Reidler P., Fink N., et al. Artificial intelligence assistance improves reporting efficiency of thoracic aortic aneurysm CT follow-up // European journal of radiology. 2021. Vol. 134, N 134. P. 109424. doi: 10.1016/j.ejrad.2020.109424

29. Tang A., Tam R., Cadrin-Chênevert A., et al. Canadian Association of Radiologists White Paper on Artificial Intelligence in Radiology // Canadian Association of Radiologists journal. 2018. Vol. 69, N 2. P. 120–135. doi: 10.1016/j.carj.2018.02.002

30. Свидетельство о государственной регистрации базы данных № 2023621046/ 30.03.2023. Васильев Ю.А., Тураилова Е.В.,

Шулькин И.М., и др. MosMedData: КТ с признаками аневризмы брюшного отдела аорты. EDN: LXROHZ

31. Алиев А.Ф., Кудрявцев Н.Д., Петрайкин А.В., и др. Оценка диаметра лёгочной артерии при различной степени тяжести течения COVID-19 (по данным бесконтрастной компьютерной томографии лёгких) // Digital Diagnostics. 2021. Т. 2, № 3. С. 249–260. EDN: VTMKCJ doi: 10.17816/DD76726

32. Морозов С.П., Шапиева А.Н., Наркевич Б.Я., и др. Информативность методов лучевой диагностики при различных патологических состояниях организма. Москва : Научно-практический клинический центр диагностики и телемедицинских технологий, 2020. EDN: DYEYBT

33. Васильев Ю.А., Владимировский А.В., Бондарчук Д.В., и др. Значение технологий искусственного интеллекта для профилактики дефектов в работе врача-рентгенолога // Врач и информационные технологии. 2023. № 2. С. 16–27. EDN: SYZAQQ doi: 10.25881/18110193_2023_2_16

REFERENCES

1. The top 10 causes of death [Internet]. World Health Organization. [cited 12 May 2023]. Available from: <https://www.who.int/ru/news-room/fact-sheets/detail/the-top-10-causes-of-death>

2. Gouveia e Melo R, Silva Duarte G, Lopes A, et al. Incidence and Prevalence of Thoracic Aortic Aneurysms: A Systematic Review and Meta-analysis of Population-Based Studies. *Seminars in thoracic and cardiovascular surgery*. 2022;34(1):1–16. doi: 10.1053/j.semtcvs.2021.02.029

3. Clinical guidelines. Guidelines for the diagnosis and treatment of aortic diseases (2017). *Russian Journal of Cardiology and Cardiovascular Surgery*. 2018;11(1):7–67. EDN: YPAKRP

4. Kuznechevsky FV, Osipov AKh, Evsikov EM, Abramov IS, Otarova SM. Prevalence and clinical features of aorta aneurysm; and dissections: 10-year results of consequent autopsies made at O.M. Filatov city clinical hospital №15. *Russian Journal of Cardiology*. 2004;9(6):5–13. EDN: ISVRYL

5. Irtuga OB, Voronkina IV, Smagina LV, et al. The frequency to detect of ascending aorta aneurysms and the mechanism of its development according register of the Almazov Federal Heart, Blood and Endocrinology Centre. *Bulletin of Almazov Federal Heart, Blood and Endocrinology Centre*. 2011;(5):73–78. EDN: OWGHOB

6. Lavall D, Schäfers HJ, Böhm M, Laufs U. Aneurysms of the ascending aorta. *Deutsches Arzteblatt international*. 2012;109(13):227–233. doi: 10.3238/arztebl.2012.0227

7. Olsson C, Thelin S, Ståhle E, Ekblom A, Granath F. Thoracic Aortic Aneurysm and Dissection. *Circulation*. 2006;114(24):2611–2618. doi: 10.1161/CIRCULATIONAHA.106.630400

8. Elefteriades JA. Natural history of thoracic aortic aneurysms: indications for surgery, and surgical versus nonsurgical risks. *The Annals of thoracic surgery*. 2002;74(5):1877–1880. doi: 10.1016/s0003-4975(02)04147-4

9. Tsai EB, Chiles C, Carter BW, et al. Incidental Findings on Lung Cancer Screening: Significance and Management. *Seminars in ultrasound, CT, and MR*. 2018;39(3):273–281. doi: 10.1053/j.sult.2018.02.005

10. Chernina VYu, Blokhin IA, Nikolaev AE, et al. *Tactics for the management of incidentalomas. Section 3. Thyroid, pituitary, vasculature and mediastinum*. Moscow: Research and Practical

Clinical Center for Diagnostics and Telemedicine; 2019. (In Russ). EDN: WSYSSYP

11. Law M. "Opportunistic" Screening. *J Med Screen*. 1994;1(4):208. doi: 10.1177/096914139400100403

12. Kumar Y, Hooda K, Li S, et al. Abdominal aortic aneurysm: pictorial review of common appearances and complications. *Annals of translational medicine*. 2017;5(12):256. doi: 10.21037/atm.2017.04.32

13. Vasilev YuA, Vladzmyrsky AV, editors. *Computer Vision in Radiologic Diagnostics: the First Stage of the Moscow Experiment*. Moscow: Limited Liability Company Izdatelskie reshenia; 2022. (In Russ). EDN: FOYLXK

14. Erbel R, Aboyans V, Boileau C, Vlachopoulos C. 2014 ESC Guidelines on the diagnosis and treatment of aortic diseases: Document covering acute and chronic aortic diseases of the thoracic and abdominal aorta of the adult. The Task Force for the Diagnosis and Treatment of Aortic Diseases of the European. *European heart journal*. 2014;35(41):2873–2926. doi: 10.1093/eurheartj/ehu281

15. Documents on the Experiment [Internet]. Center for Diagnostics and Telemedicine. [cited 16 June 2023]. Available from: <https://mosmed.ai/ai/docs/>

16. Chest-IRA [Internet]. Center for Diagnostics and Telemedicine. [cited 16 June 2023]. Available from: https://mosmed.ai/service_catalog/chestira/

17. Evangelista A, Sitges M, Jondeau G, et al. Multimodality imaging in thoracic aortic diseases: a clinical consensus statement from the European Association of Cardiovascular Imaging and the European Society of Cardiology working group on aorta and peripheral vascular diseases. *European Heart Journal Cardiovascular Imaging*. 2023;24(5):e65–e85. doi: 10.1093/ehjci/jead024

18. Etli M, Avnioglu S, Yilmaz H, Karahan O. Investigation of the correlation between cardiac parameters and aortic diameter in patients with ascending aortic aneurysm. *Egyptian Heart Journal*. 2022;74(1):1–7. doi: 10.1186/s43044-022-00238-0

19. Pearce W, Slaughter M, Lemaire S, et al. Aortic diameter as a function of age, gender, and body surface area. *Surgery*. 1993;114(4):691–697.

20. Vasilev YA, Bobrovskaya TM, Arzamasov KM, et al. Medical datasets for machine learning: fundamental principles of standartization

and systematization. *Manager Zdravoohranenia*. 2023;4:28–41. EDN: EPGAMD doi: 10.21045/1811-0185-2023-4-28-41

21. Chetverikov SF, Arzamasov KM, Andreichenko AE, et al. Approaches to Sampling for Quality Control of Artificial Intelligence in Biomedical Research. *Modern Technologies in Medicine*. 2023;15(2):19–25. EDN: FUKXYC doi: 10.17691/stm2023.15.2.02

22. Zinchenko VV, Arzamasov KM, Chetverikov SF, et al. Methodology for Conducting Post-Marketing Surveillance of Software as a Medical Device Based on Artificial Intelligence Technologies. *Modern Technologies in Medicine*. 2022;14(5):15–25. doi: 10.17691/stm2022.14.5.02

23. Chernina VY, Belyaev MG, Silin AY, et al. A diagnostic and economic evaluation of the complex artificial intelligence algorithm aimed to detect 10 pathologies on the chest CT images. *medRxiv*. 2023;4. doi: 10.1101/2023.04.19.23288584

24. Macruz FBC, Lu C, Strout J, et al. Quantification of the Thoracic Aorta and Detection of Aneurysm at CT: Development and Validation of a Fully Automatic Methodology. *Radiology: Artificial Intelligence*. 2022;4(2):e210076. doi: 10.1148/ryai.210076

25. Adam C, Fabre D, Mougin J, et al. Pre-surgical and Post-surgical Aortic Aneurysm Maximum Diameter Measurement: Full Automation by Artificial Intelligence. *European Journal of Vascular and Endovascular Surgery*. 2021;62(6):869–877. doi: 10.1016/j.ejvs.2021.07.013

26. Vladzimirskiy AV, Kudryavtsev ND, Kozhikhina DD, et al. Effectiveness of using artificial intelligence technologies for dual descriptions of the results of preventive lung examinations. *Profilakticheskaya Meditsina*. 2022;25(7):7–15. doi: 10.17116/profmed2022250717

27. Rodriguez-Ruiz A, Lång K, Gubern-Merida A, et al. Stand-Alone Artificial Intelligence for Breast Cancer Detection in Mammography: Comparison With 101 Radiologists. *Journal of the National Cancer Institute*. 2019;111(9):916–922. doi: 10.1093/jnci/djy222

28. Rueckel J, Reidler P, Fink N, et al. Artificial intelligence assistance improves reporting efficiency of thoracic aortic aneurysm CT follow-up. *European journal of radiology*. 2021;134(134):109424. doi: 10.1016/j.ejrad.2020.109424

29. Tang A, Tam R, Cadrin-Chênevert A, et al. Canadian Association of Radiologists White Paper on Artificial Intelligence in Radiology. *Canadian Association of Radiologists journal*. 2018;69(2):120–135. doi: 10.1016/j.carj.2018.02.002

30. Certificate of state registration of the database № 2023621046/30.03.2023. Vasilev YuA, Turavilova EV, Shul'kin IM, et al. MosMedData: CT scan with signs of abdominal aortic aneurysm. (In Russ). EDN: LXROHZ

31. Aliev AF, Kudryavtsev ND, Petraikin AV, et al. Changing of pulmonary artery diameter in accordance with severity of COVID-19 (assessment based on non-contrast computer tomography). *Digital Diagnostics*. 2021;2(3):249–260. EDN: VTMKCJ doi: 10.17816/DD76726

32. Morozov SP, Shapieva AN, Narkevich BYa, et al. *Informativity of radial diagnostics methods in various pathological conditions of the organism*. Moscow: Research and Practical Clinical Center for Diagnostics and Telemedicine; 2020. (In Russ). EDN: DYEYBT

33. Vasilev YuA, Vladzimirskiy AV, Bondarchuk DV, et al. Importance of artificial intelligence technologies to prevent defects in radiologist's practice. *Medical doctor and IT*. 2023;(2):16–27. EDN: SYZAOQ doi: 10.25881/18110193_2023_2_16

ОБ АВТОРАХ

* Соловьёв Александр Владимирович;

адрес: Россия, 127051, г. Москва, ул. Петровка, д. 24, стр. 1;

ORCID: 0000-0003-4485-2638;

eLibrary SPIN: 9654-4005;

e-mail: atlantis.92@mail.ru

Васильев Юрий Александрович, канд. мед. наук;

ORCID: 0000-0002-0208-5218;

eLibrary SPIN: 4458-5608;

e-mail: VasilevYA1@zdrav.mos.ru

Синицын Валентин Евгеньевич, д-р мед. наук, профессор;

ORCID: 0000-0002-5649-2193;

eLibrary SPIN: 8449-6590;

e-mail: vsini@mail.ru

Петрайкин Алексей Владимирович, д-р мед. наук;

ORCID: 0000-0003-1694-4682;

eLibrary SPIN: 6193-1656;

e-mail: alexeypetraikin@gmail.com

Владзими́рский Анто́н Вячесла́вович, д-р мед. наук;

ORCID: 0000-0002-2990-7736;

eLibrary SPIN: 3602-7120;

e-mail: VladzimirskijAV@zdrav.mos.ru

AUTHORS' INFO

* Alexander V. Solovev;

address: 24-1 Petrovka Str., Moscow, 127051, Russia;

ORCID: 0000-0003-4485-2638;

eLibrary SPIN: 9654-4005;

e-mail: atlantis.92@mail.ru

Yuriy A. Vasilev, MD, Cand. Sci. (Medicine);

ORCID: 0000-0002-0208-5218;

eLibrary SPIN: 4458-5608;

e-mail: VasilevYA1@zdrav.mos.ru

Valentin E. Sinitsyn, MD, Dr. Sci. (Medicine), Professor;

ORCID: 0000-0002-5649-2193;

eLibrary SPIN: 8449-6590;

e-mail: vsini@mail.ru

Alexey V. Petraikin, MD, Dr. Sci. (Medicine);

ORCID: 0000-0003-1694-4682;

eLibrary SPIN: 6193-1656;

e-mail: alexeypetraikin@gmail.com

Anton A. Vladzimirskiy, MD, Dr. Sci. (Medicine);

ORCID: 0000-0002-2990-7736;

eLibrary SPIN: 3602-7120;

e-mail: VladzimirskijAV@zdrav.mos.ru

* Автор, ответственный за переписку / Corresponding author

Шулькин Игорь Михайлович;

ORCID: 0000-0002-7613-5273;

eLibrary SPIN: 5266-0618;

e-mail: ShulkinIM@zdrav.mos.ru

Шарова Дарья Евгеньевна;

ORCID: 0000-0001-5792-3912;

eLibrary SPIN: 1811-7595;

e-mail: SharovaDE@zdrav.mos.ru

Семенов Дмитрий Сергеевич, канд. техн. наук;

ORCID: 0000-0002-4293-2514;

eLibrary SPIN: 2278-7290;

e-mail: SemenovDS4@zdrav.mos.ru

Igor M. Shulkin;

ORCID: 0000-0002-7613-5273;

eLibrary SPIN: 5266-0618;

e-mail: ShulkinIM@zdrav.mos.ru

Daria E. Sharova;

ORCID: 0000-0001-5792-3912;

eLibrary SPIN: 1811-7595;

e-mail: SharovaDE@zdrav.mos.ru

Dmitry S. Semenov, Cand. Sci. (Engineering);

ORCID: 0000-0002-4293-2514;

eLibrary SPIN: 2278-7290;

e-mail: SemenovDS4@zdrav.mos.ru

DOI: <https://doi.org/10.17816/DD586551>

Возможности использования виртуального симулятора «Vimedix 3.2» в процессе обучения по специальности «ультразвуковая диагностика»

В.А. Васильев, С.Н. Кондричина

Петрозаводский государственный университет, Петрозаводск, Россия

АННОТАЦИЯ

Обоснование. В последние годы актуально изменение методик и программ преподавания многих дисциплин, в том числе ультразвуковой диагностики, с включением в них различных виртуальных и симуляционных устройств. Практический опыт использования подобных технологий в процессе обучения достаточно непродолжителен, в связи с этим в отечественной и зарубежной литературе имеются лишь немногочисленные оригинальные работы, посвящённые этой теме.

Цель — определить возможности и алгоритм использования виртуального симулятора ультразвукового исследования в процессе преподавания дисциплины «ультразвуковая диагностика» на основании результатов работы с ним. Оценить преимущества и недостатки применения симулятора в сравнении с традиционной методикой преподавания.

Материалы и методы. Проанализированы результаты применения виртуального тренажёра «Vimedix 3.2» в учебном процессе. На нём проводились симуляции трансабдоминального ультразвукового исследования органов брюшной полости, трансторакальной эхокардиографии, триплексного сканирования магистральных сосудов. В процессе исследования участвовали 26 ординаторов по специальности «ультразвуковая диагностика» и 37 врачей, проходивших обучение на курсах профессиональной переподготовки.

Результаты. Применение виртуального симулятора на начальном этапе в учебном процессе может устранить многие проблемы, с которыми сталкиваются ординаторы и курсанты при обучении на клинических базах. Использование симулятора в процессе тестирования представляется менее предпочтительным, по сравнению с практическим экзаменом с использованием ультразвуковых сканеров и реальных пациентов.

Заключение. Симулятор целесообразно использовать на начальном этапе для отработки методики исследования. Рекомендуются разработка и использование в обучении дополнительных учебно-методических материалов и учебной программы. Преимуществами виртуального симулятора являются комфортность работы на начальном этапе обучения, малое время его освоения, наличие обширной базы данных патологических случаев. Выявленные некритичные недостатки требуют коррекции при дальнейшем обучении в клинике.

Ключевые слова: симуляционное обучение; виртуальный тренажёр; симулятор ультразвуковых исследований; ультразвуковая диагностика.

Как цитировать:

Васильев В.А., Кондричина С.Н. Возможности использования виртуального симулятора «Vimedix 3.2» в процессе обучения по специальности «ультразвуковая диагностика» // Digital Diagnostics. 2024. Т. 5, № 1. С. 41–52. DOI: <https://doi.org/10.17816/DD586551>

DOI: <https://doi.org/10.17816/DD586551>

Possibilities for using the Vimedix 3.2 virtual simulator to train ultrasound specialists

Valeri A. Vasilev, Svetlana N. Kondrichina

Petrozavodsk State University, Petrozavodsk, Russia

ABSTRACT

BACKGROUND: In recent years, it has been critical to modify training methods and programs in numerous areas, including ultrasound diagnosis, with the use of various virtual and simulation devices. Because practical experience with employing such technologies in the teaching process is limited, there are few original studies on the subject in Russian and foreign literature.

AIM: To determine the possibilities and algorithms for using a virtual ultrasound simulator to train ultrasound specialists based on the results of related work, as well as to assess the benefits and drawbacks of simulators in comparison to conventional teaching methods.

MATERIALS AND METHODS: The results of using the Vimedix 3.2 virtual simulator in the teaching process were analyzed. Simulations of abdominal ultrasound, transthoracic echocardiography, and triplex scanning of major vessels were performed. The study included 26 residents specializing in ultrasound diagnosis and 37 physicians undergoing professional retraining courses.

RESULTS: Using a virtual simulator during the initial stage of training helps eliminate many of the challenges that residents and trainees encounter in clinical practice. The use of a simulator during testing appears to be less beneficial than during a practical examination employing ultrasound scanners and real patients.

CONCLUSIONS: The use of a simulator at the initial stage is advisable to get familiar with this research methodology. It is recommended to develop and use of additional teaching materials and programs in training. The advantages of the virtual simulator include ease of use during the initial stages of training, a steep learning curve, and the availability of an extensive database of pathological cases. The identified noncritical shortcomings require correction during further training in the clinic.

Keywords: simulation training; virtual simulator; ultrasound simulator; ultrasound diagnosis.

To cite this article:

Vasilev VA, Kondrichina SN. Possibilities for using the Vimedix 3.2 virtual simulator to train ultrasound specialists. *Digital Diagnostics*. 2024;5(1):41–52.
DOI: <https://doi.org/10.17816/DD586551>

DOI: <https://doi.org/10.17816/DD586551>

在“超声诊断”专业教学过程中使用虚拟模拟器“Vimedix 3.2”的可行性

Valeri A. Vasilev, Svetlana N. Kondrichina

Petrozavodsk State University, Petrozavodsk, Russia

摘要

论证。近年来，包括超声诊断在内的许多学科的教学方法和课程发生了变化，教学计划包括在各种虚拟和模拟设备上练习。在教学过程中使用此类技术的实践经验相当少，在这方面，国内外文献中有关这一主题的原创作品寥寥无几。

目的。本研究的目的是根据使用虚拟超声模拟器的结果，确定在“超声诊断”学科教学过程中使用该模拟器的可行性和算法；评估使用模拟器与传统教学方法相比的优缺点。

材料和方法。分析了在教学过程中使用虚拟模拟器“Vimedix 3.2”的结果，在该模拟器上进行了腹腔器官经腹超声检查、经胸超声心动图检查、大血管的三重扫描。研究的参与者包括26名“超声诊断”专业的住院医师和37名接受过职业进修课程的医生。

结果。在教学过程的初始阶段使用虚拟模拟器可以消除住院医师和学员在临床现场学习时遇到的许多问题。与使用超声波扫描仪和真正患者进行实践考试相比，在测试过程中使用模拟器似乎不太可取。

结论。在初始阶段使用模拟器来练习检查方法是可行的。建议在教学中开发和使用额外的教材和教学计划。虚拟模拟器的优点是在教学初期使用方便，掌握时间短，有大量病例数据库。已发现的非关键缺点需要在临床进一步培训中加以纠正。

关键词：模拟训练；虚拟模拟器；超声模拟器；超声诊断。

引用本文：

Vasilev VA, Kondrichina SN. 在“超声诊断”专业教学过程中使用虚拟模拟器“Vimedix 3.2”的可行性. *Digital Diagnostics*. 2024;5(1):41–52. DOI: <https://doi.org/10.17816/DD586551>

收到: 20.09.2023

接受: 18.01.2024

发布日期: 11.03.2024

ОБОСНОВАНИЕ

В последние годы мы стали свидетелями всё более широкого применения виртуальных и симуляционных технологий в разных областях медицинской деятельности и в процессе преподавания в медицинских вузах. Различные виды симуляции реальных процессов достаточно давно используются в процессе обучения и работы специалистов многих направлений, их разработка ведётся несколько десятилетий [1–3]. Ускорение этого процесса обусловлено как общей цифровизацией нашей жизни, так и активным внедрением подобных технологий непосредственно в практическую медицину.

Виртуальные тренажёры и симуляторы, средства дополненной реальности всё активнее используются в клиниках не только в диагностических исследованиях, но и в лечебной практике в таких областях, как хирургия, анестезиология и реаниматология и др. К ним можно отнести 3D «анатомические» и визуализационные столы, программы виртуальной реальности для изучения анатомии человека, хирургические тренажёры и роботы и др. [4–6]. Как следствие, цифровые методики стали применяться как в процессе обучения, так и при контроле знаний выпускников медицинских вузов, а также специалистов, проходящих переобучение, при проведении государственных аттестаций и аккредитаций, в том числе по специальности «ультразвуковая диагностика» (УЗД) [1, 7]. Другой причиной повышения интереса к подобным технологиям является то, что медицинские институты и учреждения последиplomного образования в последнее время сталкиваются с нарастающими трудностями в обучении ряда дисциплин в клиниках на рабочем месте.

К ним можно отнести сложности, связанные непосредственно с работой в клинике: ограничения по месту и времени проведения исследований [7, 8], нехватка аппаратов для проведения ультразвукового исследования (УЗИ), недостаток наставников, проблемы с доступом в отделения при введении карантина. Другая часть трудностей связана с реальными обследуемыми: психологическое давление на студентов при первых контактах с пациентом, нежелание части пациентов проходить обследование у обучающихся [8], отсутствие в клинике пациентов с необходимой патологией, плохая визуализация у так называемых «трудных» пациентов и т.д. Третья часть проблем определяется уровнем теоретической подготовки и активностью в процессе работы самих обучающихся, что может существенно увеличить время отработки необходимых навыков, которое в клинике лимитировано. Кроме того, можно выделить такой момент, как сложность отработки методики исследования вследствие недостаточного уровня знаний нормальной и патологической анатомии. В первую очередь это относится к правильному позиционированию датчика, что может

потребовать продолжительного времени и создать дискомфорт у обследуемого.

В связи с этим изменение методик и программ преподавания ряда дисциплин в медицинских вузах, с включением в них различных современных виртуальных и симуляционных устройств, — актуальная и необходимая задача. При обучении специалистов в области лучевой диагностики этот вопрос особенно важен, так как они уже давно работают с программами создания и обработки цифровых изображений и должны обладать необходимыми навыками и знаниями для этого.

Вместе с тем, опыт использования подобных технологий в преподавании медицинских дисциплин достаточно непродолжителен. В связи с этим в отечественной и зарубежной литературе имеются лишь немногочисленные оригинальные работы, посвящённые этой теме. В большинстве из них указывается на положительные моменты использования симуляционных технологий в обучении специалистов по УЗД [7–10], хотя имеются указания и на отдельные недостатки, в частности — при проведении тестирования и контроля знаний [7]. Практически отсутствуют стандартизированные подходы к симуляционному обучению в области УЗД, рациональному использованию виртуальных тренажёров и определению их конкретного места в учебном процессе, а также оценке результатов их применения. Мало информации о разработке и эффективности использования специальных учебных модулей и методических материалов, направленных на освоение того или иного типа симуляторов и тренажёров.

В связи с этим мы решили проанализировать наш опыт работы с современными цифровыми технологиями в процессе преподавания и контроля знаний на примере симулятора УЗИ. Виртуальный тренажёр используется в процессе изучения дисциплины «ультразвуковая диагностика» на кафедре лучевой диагностики и лучевой терапии медицинского института Федерального государственного бюджетного образовательного учреждения высшего образования «Петрозаводский государственный университет» в течение четырёх лет. С ним работают ординаторы первого и второго года обучения и врачи-курсанты, проходящие профессиональную переподготовку. Симулятор используется при прохождении государственной итоговой аттестации ординаторами и в процессе первичной аккредитации специалистов по этой дисциплине.

ЦЕЛЬ

Определить возможности и алгоритм использования виртуального симулятора УЗИ в процессе преподавания дисциплины «ультразвуковая диагностика» на основании результатов работы с ним. Оценить преимущества и недостатки применения симулятора в сравнении с традиционной методикой преподавания.




Рис. 1. Виртуальный симулятор ультразвуковых исследований «Vimedix 3.2».

МАТЕРИАЛЫ И МЕТОДЫ

В нашей работе оценивались результаты применения в учебном процессе виртуального тренажёра УЗИ «Vimedix 3.2» производства CAE Healthcare (Канада). Этот симулятор является наиболее распространённым на российском и зарубежном рынках. Он оснащается несколькими манекенами и датчиками для отработки методик исследования различных областей, а также имеет базу данных патологических случаев. В составе тренажёра имеется ноутбук «Omen» производства Hewlett-Packard (США) с беспроводным подключением, мышь, мужской

многоцелевой манекен, ультразвуковой конвексный датчик с фазированной решёткой, адаптер для подключения датчика (рис. 1).

На ноутбуке установлено оригинальное программное обеспечение (ПО) для симуляции ультразвукового сканирования, позволяющее проводить исследования в 2D, а также 3D/4D анатомических режимах с помощью мультипланарной реконструкции. Для этого применяется технология смешанной реальности Microsoft HoloLens 2 (США), с помощью которой обучаемый может визуализировать изучаемые анатомические структуры в режиме «live», то есть движения. Эта технология используется для облегчения навигации по исследуемой области при оценке изображений, полученных с помощью томографических методов лучевой диагностики [11, 12], а в тренажёре — для правильного позиционирования датчика при проведении симуляции [13]. В рабочем пространстве экрана ноутбука вместе с изображением, получаемым в 2D-режиме, выводится отдельное окно, в котором отображается 3D/4D анимированное анатомическое изображение, показывающее органы, попадающие в зону сканирования. Оператор имеет возможность управлять отображением анатомических структур и разделением окон для удобства визуализации (рис. 2).

На тренажёре возможна симуляция таких исследований, как трансабдоминальное УЗИ органов брюшной полости, трансторакальная эхокардиография, сканирование магистральных сосудов. Возможно проведение сканирования в таких режимах, как:

- В (2D, двухмерная эхография);




Рис. 2. Интерфейс программы симуляции в режимах смешанной реальности и 2D.

- М (одномерная эхография);
- цветовой доплеровский (Color Doppler, CD);
- импульсно-волновой доплеровский (Pulsed Wave, PW).

Перемещение датчика по поверхности манекена отслеживается специальной системой маркёров, которая позволяет проводить исследования при различных положениях тела (на спине, на боку). Для оценки результатов имеется набор основных необходимых инструментов, таких как измерения длины, площади и объёма, скорости кровотока в доплеровских режимах, расчёта показателей центральной гемодинамики при проведении эхокардиографии. Можно сформировать итоговый протокол по результатам исследования и проведённых измерений.

Виртуальный симулятор имеет достаточно обширную базу ультразвуковых изображений с различной патологией органов брюшной полости и сердечно-сосудистой системы. Это даёт возможность при обучении осваивать методику исследования различных областей не только при нормальной анатомии, но и при различных заболеваниях. При проведении контроля знаний соответственно можно оценивать умение аттестуемых находить и описывать различные виды патологических изменений по стандартным протоколам.

Всего в процессе исследования участвовали 26 ординаторов по специальности «ультразвуковая диагностика» и 37 врачей, проходивших обучение на курсах профессиональной переподготовки по этой же специальности. Поскольку в нашей работе использовались категориальные данные и два варианта ответов, то имеющееся количество специалистов достаточно для оценки применения предложенного метода обучения для всех слушателей курса УЗД не только за оцениваемый в работе период, но и в дальнейшем. Оценка результатов работы с тренажёром проводилась сотрудниками кафедры лучевой диагностики и лучевой терапии с участием практикующих врачей-диагностов клинических баз института, принимающих участие в процессе обучения и контроля знаний.

В нашей работе для определения результатов использования виртуального тренажёра мы использовали в первую очередь показатели, необходимые для организации и планирования педагогического процесса:

- время, необходимое для освоения тренажёра (включая обучение запуску ПО и работе с интерфейсом);
- простота освоения и психологический комфорт;
- удобство обращения с датчиком и манекеном;
- правильность позиционирования датчика (с помощью анатомических ориентиров манекена и технологии смешанной реальности);
- возможность самостоятельной работы обучаемых на симуляторе;
- необходимость наличия специальных учебно-методических материалов и коррекции существующей программы обучения.

Часть ординаторов и курсантов, имевших до этого опыт работы на ультразвуковых сканерах в клинике, оценивали качество изображения, создаваемого на симуляторе, и его соответствие изображению, получаемому при исследовании реальных пациентов.

Данные собирались путём анонимного анкетирования обучающихся с использованием шкалы Лайкерта [14] и выставлением баллов от 0 до 5 по предлагаемым вопросам (рис. 3 и 4).

В процессе занятия преподаватель анализировал процесс работы с оборудованием по оцениваемым критериям, а в конце занятия преподаватели и наставники, работающие в клинике, при помощи тестов и заданий оценивали результаты усвоения теоретических знаний и практических навыков. Мы учитывали, что большинство оцениваемых критериев являются субъективными, что затрудняет интерпретацию результатов, но это обусловлено общей спецификой УЗИ, в частности — его высокой операторзависимостью. Совместно с обучаемыми также фиксировались возникавшие в процессе обучения проблемы и анализировались причины их возникновения и пути устранения.

Соответствие нормам этики

Информированное добровольное согласие лицами, участвующими в процессе обучения и исследования, не подписывалось. Сбор данных проводился методом добровольного анонимного анкетирования, никакие персональные данные в процессе работы не собирались и не обрабатывались. Пациенты в процессе исследования участия не принимали.

РЕЗУЛЬТАТЫ

При оценке преимуществ и недостатков использования виртуального тренажёра в процессе обучения проводилось сравнение с традиционной методикой, когда ординаторы и врачи проходят стажировку с использованием ультразвуковых сканеров на реальных пациентах в клинике под руководством наставников — сотрудников кафедры и практикующих врачей. При таком подходе мы сталкиваемся с рядом известных проблем, количество которых увеличилось в последние годы из-за пандемии COVID-19 [15].

По результатам обучения было отмечено, что все ординаторы и большая часть курсантов (81%) успешно завершили обучение на виртуальном симуляторе УЗИ. К критериям успешности относили уверенную работу с ПО тренажёра и интерфейсом симулятора (включение, настройка), полное овладение методикой исследования той или иной области (табл. 1).

Минимальное время, необходимое для освоения тренажёра, составило от 2 до 6 занятий по два академических часа под контролем преподавателя кафедры и одну вводную лекцию (1 академический час, 45 мин).

Анкета для ординаторов и курсантов, обучающихся по специальности «Ультразвуковая диагностика»

Анкетирование анонимное, никакие персональные данные указывать **не нужно**

Вопросы, где в ответе есть прочерк, оцениваете в баллах от 1 до 5, где
1 - полностью не согласен, 2 - не согласен, 3 - где-то посередине,
4 - согласен, 5 - полностью согласен.
Вопросы, где имеются два варианта ответов – выбираете один

1. Мне удалось полностью овладеть навыками работы на симуляторе ультразвуковых исследований.

Ответ__ баллов

2. Я полностью овладел(-а) методикой исследований отдельных областей при обучении на симуляторе УЗИ.

Ответ__ баллов

3. Мне было легко овладеть навыками работы на симуляторе ультразвуковых исследований.

Ответ__ баллов

4. Мне было трудно овладеть навыками работы на симуляторе ультразвуковых исследований.

Ответ__ баллов

5. Я бы выбрал симулятор ультразвуковых исследований для обучения методике ультразвукового сканирования

Да Нет

6. Я бы выбрал исследование на реальных пациентах для обучения методике ультразвукового сканирования

Да Нет

7. Мне было трудно обучиться работе с программным обеспечением ультразвукового симулятора

Ответ__ баллов

8. Мои знания по информатике достаточны для уверенной работы на симуляторе ультразвукового исследования

Ответ__ баллов

9. Мои знания по информатике недостаточны для уверенной работы на симуляторе ультразвукового исследования

Ответ__ баллов

Рис. 3. Анкета для ординаторов и курсантов, часть 1.

10. Обучение на симуляторе ультразвукового исследования было для меня более психологически комфортным, чем обучение в клинике на реальных пациентах

Ответ__ баллов

11. Обучение в клинике на реальных пациентах было для меня более психологически комфортным, чем обучение на симуляторе ультразвуковых исследований

Ответ__ баллов

12. Я предпочитаю пройти итоговое тестирование по специальности на симуляторе ультразвуковых исследований

Ответ__ баллов

13. Я предпочитаю пройти итоговое тестирование по специальности на реальных пациентах в клинике

Ответ__ баллов

14. Подготовка к итоговому тестированию на симуляторе ультразвукового исследования была для меня более психологически комфортна, чем обучение в клинике на реальных пациентах

Ответ__ баллов

15. Подготовка к итоговому тестированию на в клинике на реальных пациентах была для меня более психологически комфортна, чем с помощью симулятора УЗИ

Ответ__ баллов

16. Больше времени потребовалось мне для овладения навыками ультразвукового сканирования при использовании симулятора УЗИ по сравнению с обучением в клинике на реальных пациентах.

Да Нет

17. Больше времени потребовалось мне для овладения навыками ультразвукового сканирования при обучении в клинике на реальных пациентах, чем при использовании симулятора УЗИ

Да Нет

18. Качество изображения внутренних органов на экране симулятора УЗИ не уступает качеству изображения на экране ультразвуковых сканирующих системы, с которыми вы работали (если не работали, не отвечайте на этот вопрос).

Ответ__ баллов

Комментарий (добавьте свое мнение по вопросам, не указанным в анкете, укажите сложности, которые возникали у вас при работе с симулятором УЗИ)

Рис. 4. Анкета для ординаторов и курсантов, часть 2.

Отмечено, что ординаторы в целом быстрее осваивали работу на симуляторе, по сравнению с курсантами. Это, на наш взгляд, обусловлено имеющейся у них теоретической базой (лекции на курсе лучевой диагностики) и определённым опытом работы с ультразвуковой техникой. Для большинства их них (75%) было достаточно 2–3 занятий под руководством наставника, после чего они могли переходить к преимущественно самостоятельной работе по удобному для них графику. Что касается врачей, обучающихся на курсах, то для более возрастных обучающихся (категория 50 лет и старше) требовалось минимум 3–4, максимум 6 занятий для освоения базовых навыков

работы на тренажёре. При этом мы столкнулись с проблемой, когда у части обучающихся (26%) уровень подготовки в области компьютерных технологий был или нулевой, или низкий базовый, не позволяющий даже после курса обучения самостоятельно запускать ПО ноутбука и уверенно пользоваться интерфейсом приложения симулятора. Для оценки результатов работы с виртуальным тренажёром использовались тесты, основанные на заданиях, выполняемых в процессе прохождения первичной аккредитации специалистов по УЗД (рис. 5).

Значительная часть обучаемых (72%) отмечали больший психологический комфорт при работе с тренажёром

Таблица 1. Результаты анкетирования и тестирования обучавшихся

	Ординаторы	Врачи
Количество обучавшихся	26	37
Успешное освоение тренажёра	100%	81%
Минимально необходимое количество времени на освоение тренажёра, мин	90	135
Психологический комфорт при освоении методик сканирования на тренажёре	80%	68%
Психологический комфорт при подготовке к тестированию/аккредитации на тренажёре	90%	75%
Удовлетворительное качество изображения на тренажёре в режимах М и В	95%	95%
Удовлетворительное качество изображения на тренажёре в доплеровских режимах	90%	89%
Положительная оценка использования программы 3D/4D-навигации	100%	100%
Предпочтение тренажёру при прохождении итогового тестирования и аккредитации	100%	90%

Тестовое задание для оценки результатов освоения методики исследования в В-режиме на симуляторе УЗИ
(1 вариант с использованием режима MR, 2 вариант без использования режима MR).
Время выполнения 10 мин.

1. Включить виртуальный тренажер, запустить программу симуляции ультразвукового исследования.
2. Придать манекену правильное положение для исследования _____ в продольной плоскости сканирования, используя/не используя технологию MR.
3. Определить точки для определения размеров и провести измерения, озвучить полученные результаты.
4. Вывести исследуемый орган _____ в поперечной плоскости сканирования, используя/не используя технологию MR.
5. Определить точки для определения размеров и провести измерения, озвучить полученные результаты.
6. Оценить эхоплотность и эхоструктуру органа. Озвучить полученные результаты.
7. Оценить контуры органа и дать их описание.
8. При наличии патологических изменений в органе дать их оценку по схеме:
- локализация
- размеры
- форма
- эхоплотность и эхоструктура
- контуры
- дополнительные элементы (артефакты и др)
9. Сформировать и озвучить протокол заключения по исследуемому органу, включающий оцениваемые показатели.

Тестовое задание для оценки результатов освоения методики исследования в доплеровских режимах на симуляторе УЗИ
(1 вариант с использованием режима MR, 2 вариант без использования режима MR).
Время выполнения 10 мин.

1. Включить виртуальный тренажер, запустить программу симуляции ультразвукового исследования.
2. Придать манекену правильное положение для исследования сердца.
3. Вывести изображение сердца в апикальной пятикамерной позиции в В-режиме.
4. Включить режим цветового доплеровского картирования кровотока (ЦДК) и установить зону исследования в области митрального клапана.
5. Продемонстрировать трансмитральный кровоток в режиме ЦДК и оценить его направление и характер. Озвучить результаты.
6. Включить импульсноволновой доплеровский режим и установить контрольный объем над створками митрального клапана. Продемонстрировать спектр трансмитрального кровотока.
7. Измерить скорость и оценить характер спектра трансмитрального потока крови и озвучить результат.
8. Установить зону исследования режима ЦДК в области аортального клапана.
9. Продемонстрировать кровоток в выходном отделе левого желудочка в режиме ЦДК и оценить его направление и характер. Озвучить результаты.
10. Установить контрольный объем импульсноволнового доплеровского режима в выходном отделе левого желудочка. Продемонстрировать спектр кровотока.
11. Измерить скорость и оценить характер спектра потока крови в выходном отделе левого желудочка и озвучить результат.
12. Установить контрольный объем импульсноволнового доплеровского режима в надклапанном отделе аорты. Продемонстрировать спектр кровотока.
13. Измерить скорость и оценить характер спектра потока крови в надклапанном отделе аорты и озвучить результат.
14. Сформировать и озвучить заключение по результатам исследований кровотока через митральный и аортальный клапаны в доплеровских режимах.

Рис. 5. Тестовые задания для оценки результатов освоения методик исследования.

во время освоения первичных навыков методики УЗИ, по сравнению с обучением на реальных пациентах в условиях клиники. Этот критерий оценивали только имеющие практический опыт работы (пусть и небольшой) на ультразвуковых сканерах. По мнению наставников и самих обучающихся, на начальном этапе это облегчает и ускоряет отработку методики исследования, однако не снимает проблему первого контакта с пациентом, которую придётся решать при последующей практической работе. В основном это касалось ординаторов, не имеющих ранее опыта такого взаимодействия.

Работа на симуляторе была достаточно легко встроена в график обучения, поскольку он располагается в здании медицинского института, и мы не зависели от режима работы медицинских учреждений. Этот факт помогает решить и проблему нехватки помещений, а также ограничения времени на обучение в клинике. Нами было опробовано и в последующем практиковалось объединение обучающихся в группы, что позволяет создать учебный график, удобный и для преподавателя, и для учащихся. Исходя из нашего опыта, оптимальными

для одновременной работы на виртуальном симуляторе являются малые группы количеством до 3 человек. Такой расчёт обусловлен количеством времени, необходимым для освоения нового материала в процессе занятия одним обучающимся, и размерами помещения.

Качество изображения, получаемого в режимах В и М, в целом характеризовалось обучающимися как хорошее (95% ответов), в доплеровских режимах — как удовлетворительное (89%). Критериями являлись трудность распознавания и интерпретации получаемых изображений и возможность их соотнесения с реальными анатомическими объектами. Проблемой, выявленной при использовании доплеровских режимов, стала невозможность регулировки некоторых параметров доплеровских режимов, вследствие чего кровотоки в режимах CD и PW чётко визуализировались только через клапаны сердца и в некоторых отделах аорты.

Всеми обучаемыми отмечено, что использование дополнительного окна с режимом смешанной реальности и 3D/4D-live анатомической навигацией исследуемой области существенно облегчало отработку позиционирования датчика при исследовании всех областей. Особенно это было удобно при оценке органов брюшной полости и сердца [12].

При использовании режима В нами была выявлена такая проблема, как не вполне правильное позиционирование датчика на манекене для получения некоторых стандартных проекций сердца (например, апикальной), что потребует в последующем коррекции при отработке навыков на пациентах. В этих случаях обучающиеся для решения проблемы успешно использовали систему смешанной реальности, с помощью которой можно точно оценить плоскости сечения органа и положение датчика относительно анатомических ориентиров.

По результатам опросов, по сравнению с отработкой методики на реальных пациентах практически всеми (95%) — и ординаторами, и врачами — отдавалось предпочтение тренажёру. Время отработки методики исследования одной области на симуляторе в среднем составило от 1 до 2 занятий по 2 академических часа. Отработка методики включала полипозиционное исследование при различных положениях манекена, при этом мы не ограничивали длительность одного сканирования, что приходится делать в условиях клиники. При переходе к работе на реальных ультразвуковых сканерах полученные навыки исследования различных областей нами характеризовались как удовлетворительные, требующие лишь небольшой по времени коррекции в плане позиционирования датчика и умений работать с «трудными пациентами» и в определённые фазы дыхания.

Что касается методики преподавания, то, по нашему мнению, она должна отличаться от практики, используемой в клинике под руководством наставников. Если там используется два основных подхода — наблюдение за исследованием и повторение действий наставника

на пациенте, то здесь дополнительно можно использовать принцип самостоятельного обучения методом проб и ошибок. На наш взгляд, такой подход более комфортен для обучающихся (хотя бы вследствие отсутствия временных ограничений и психологического давления) и может давать лучшие практические результаты. Он был реализован нами в процессе обучения в виде самостоятельной работы обучающихся на тренажёре по удобному для них графику. При необходимости преподаватель давал консультацию в дистанционном формате с помощью аудио- и видеосвязи.

Кроме того, возможен переход от классической схемы «один наставник — один стажёр» к системе группового обучения на начальном этапе, что более выгодно и с экономической точки зрения. Тренажёр позволил совместить во время одного занятия как теоретическую, так и практическую часть изучаемого материала. Сначала преподавателем читалась вводная лекция по той или иной теме с демонстрацией на симуляторе, затем полученный материал закреплялся во время практической работы обучающихся (рис. 6). Такой принцип оказался удобным при изучении начальной методики исследования отдельных областей и при подготовке к тестированию.

Что касается использования виртуального тренажёра для контроля знаний при прохождении аттестации ординаторов и аккредитации специалистов, то здесь получены неоднозначные результаты, дающие возможность для дискуссии. В ряде подобных исследований авторами делается акцент на положительные стороны такого применения симуляторов, в частности, отсутствие стресса у аттестуемых и приближенные к реальности условия [8, 15]. Эти данные согласуются с мнением большинства обучающихся (95%), которые по результатам опросов предпочитали сдавать практические навыки на тренажёре, причём эта оценка совпадала на этапах до тестирования и после него. Однако, по мнению сотрудников кафедры и практических наставников, в таком варианте

тестирования больше отрицательных моментов, чем положительных.

ОБСУЖДЕНИЕ

Таким образом, исходя из результатов применения виртуального симулятора «Vimedix 3.2», его можно рекомендовать для использования на начальном этапе обучения по специальности «ультразвуковая диагностика». Наш опыт подтверждает полезность интеграции систем виртуальной и дополненной реальности в медицинский образовательный процесс и в учебные программы по УЗД, на что указывают многие авторы [8–10, 15]. С помощью тренажёра удобно отрабатывать методику исследования тех или иных областей, пользоваться анатомическими ориентирами для позиционирования датчика, учиться проводить основные измерения в различных режимах, включая доплеровские. Однако его использование не заменяет, а только дополняет клинический опыт работы, и на последующих этапах должна проводиться повторная отработка (и коррекция) практических навыков при исследовании реальных пациентов под руководством наставника.

Пока относительно мало данных о том, как навыки, приобретённые с помощью обучения с применением симуляционных технологий, коррелируют с клинической эффективностью, а также насколько они окажутся устойчивыми в долгосрочной перспективе [16, 17]. Именно поэтому для более точной оценки эффективности обучения, по нашему мнению, целесообразно проведение практического тестового контроля у выпускников через несколько лет после начала самостоятельной работы. Для этого может использоваться система критериев объективной структурированной оценки ультразвуковых навыков (OSAUS) [18].

Для эффективного освоения симулятора целесообразно составление отдельной инструкции по работе с ним, включающей моменты запуска приложения и руководство по использованию интерфейса в виде пошаговых действий для тех или иных задач. Для самостоятельной работы обучающихся оптимально подготовить вводную лекцию, знакомящую ординаторов и курсантов с основами работы ПО тренажёра, а также с демонстрацией его возможностей преподавателем. В этом плане полезными будут и методические рекомендации по исследованию определённых анатомических областей манекена на тренажёре. Для освоения методики исследования отдельных областей удобными оказались учебные модули длительностью 2 академических часа, один — для демонстрации материала преподавателем, и один — для самостоятельной работы обучающихся. В связи с разным уровнем подготовки обучающихся в области информатики возможно использование двух вариантов программы обучения — с большим и меньшим временем, посвящённым навыкам работы с ПО тренажёра.



Рис. 6. Самостоятельная работа на тренажёре ординатора второго года обучения.

В целом, для полноценного освоения возможностей симулятора требуется минимум 5–6 занятий с преподавателем, распределённых по разным областям исследования. Они могут включать такие темы, как повторение нормальной анатомии, отработка позиционирования, использование ультразвуковых режимов, параметры оценки органов и др. В дальнейшем может проводиться самостоятельная работа обучающихся в удобное для них время, в том числе с дистанционным контролем преподавателя для решения возникающих вопросов. Кроме того, виртуальный симулятор можно использовать для обучения диагностике тех заболеваний, которые не встретились при исследовании реальных пациентов в клинике, — с помощью базы патологических случаев, заложенных в ПО.

Что касается итоговой оценки знаний, то, по нашему мнению, её предпочтительнее проводить на ультразвуковых сканерах и реальных пациентах, когда можно определить умение аттестуемого ориентироваться в той или иной конкретной клинической ситуации. При этом оптимальным, хотя и более сложным, представляется проведение исследования как у пациентов без патологии, так и с наличием определённого заболевания, которое ординатор или курсант должен уметь продемонстрировать наставнику и грамотно описать в стандартном протоколе. Позиция ординаторов и курсантов, предпочитающих использование симулятора, обусловлена тем, что подготовка к прохождению и выполнение самого практического теста протекает психологически более комфортно, по сравнению с его выполнением в клинике. Она не требует больших временных затрат, проводится без привлечения пациентов и использования клинического оборудования, может быть выполнена в любое время самостоятельно, а сами обучающиеся не испытывают стресса.

С точки зрения преподавателей, подготовка к сдаче практических навыков сводится преимущественно к механическому заучиванию определённых действий. Во время тестирования экспертами также оценивается в основном выполнение и порядок тех или иных действий, но не их качество и результат. Система чек-листов и дистанционного наблюдения не позволяет детально оценить корректность получаемых испытуемым изображений, а также давать дополнительные задания в сомнительных случаях. Нет возможности оценить работу с различными типами телосложения пациентов, оцениваются стандартизированные нормальные анатомические изображения в условиях отсутствия дыхательных движений, не проводится полипозиционное сканирование. Однако здесь уже возникают вопросы не столько к принципу работы самого тренажёра и его возможностям, сколько к имеющимся методикам и принципам тестирования.

Если оценивать программно-техническое оснащение виртуального тренажёра УЗИ «Vimedix 3.2», то оно

позволяет проводить достаточно полноценную симуляцию основных видов исследования, которыми должен овладеть специалист в процессе обучения. В связи с этим, по нашему мнению, возможно его усовершенствование и расширение области применения для обучения таким актуальным методикам, как пункции различных органов под контролем ультразвука и эхоэндоскопические исследования органов желудочно-кишечного тракта.

ЗАКЛЮЧЕНИЕ

Симулятор «Vimedix 3.2» целесообразно использовать на начальном этапе обучения специалистов УЗИ для отработки методики исследования различных областей, в том числе при конкретных клинических ситуациях. Использование тренажёра для проведения аттестации и аккредитации на данном этапе, по нашему мнению, представляется менее предпочтительным, чем тестирование на реальных пациентах в условиях клиники. Для полноценного использования симулятора рекомендуется разработка и использование в обучении дополнительных методических материалов и учебных модулей, изменение подходов к освоению практических навыков.

Основными преимуществами использования виртуального симулятора «Vimedix 3.2» в образовательном процессе являются психологический комфорт работы для обучающихся, небольшое время его освоения, возможность работы в группе, наличие обширной базы данных патологических случаев, размещение в здании медицинского вуза.

К выявленным недостаткам использования тренажёра относятся невозможность отрабатывать практические моменты, касающиеся работы с пациентом, ошибки позиционирования датчика, не всегда удовлетворительное качество изображения в режиме CD. Они не являются критичными, однако требуют последующей коррекции полученных навыков при работе в клинике.

ДОПОЛНИТЕЛЬНАЯ ИНФОРМАЦИЯ

Источник финансирования. Авторы заявляют об отсутствии внешнего финансирования при проведении исследования.

Конфликт интересов. Авторы декларируют отсутствие явных и потенциальных конфликтов интересов, связанных с публикацией настоящей статьи.

Вклад авторов. Все авторы подтверждают соответствие своего авторства международным критериям ICMJE (все авторы внесли существенный вклад в разработку концепции, проведение исследования и подготовку статьи, прочли и одобрили финальную версию перед публикацией).

Наибольший вклад распределён следующим образом: В.А. Васильев — концепция и дизайн исследования, анализ полученных данных, написание текста статьи; С.Н. Кондричина — сбор и обработка материалов.

ADDITIONAL INFORMATION

Funding source. This study was not supported by any external sources of funding.

Competing interests. The authors declare that they have no competing interests.

СПИСОК ЛИТЕРАТУРЫ

1. Meller G. A typology of simulators for medical education // *J Digit Imaging*. 1997. Vol. 10, Suppl. 1. P. 194–196. doi: 10.1007/BF03168699
2. Gaba D.M. The future vision of simulation in health care // *Quality and Safety in Health Care*. 2004. Vol. 13, Suppl. 1. P. 2–10. doi: 10.1136/qshc.2004.009878
3. Alinier G. A typology of educationally focused medical simulation tools // *Medical Teacher*. 2007. Vol. 29, N 8. P. 243–250. doi: 10.1080/01421590701551185
4. Горшков М.Д., Никитенко А.И. Применения виртуальных симуляторов в обучении эндохирургов — обзор российского и мирового опыта // *Виртуальные технологии в медицине*. 2009. Т. 1, № 1. С. 15–18. EDN: QBAVGC doi: 10.46594/2687-0037_2009_1_18
5. Горшков М.Д., Федоров А.В. Классификация симуляционного оборудования // *Виртуальные технологии в медицине*. 2012. Т. 2, № 8. С. 23–35. EDN: BJWHJB doi: 10.46594/2687-0037_2012_2_21
6. Симуляционное обучение в медицине / под ред. А.А. Свистунова. Москва : Издательство Первого МГМУ им. И.М. Сеченова, 2013. EDN: XVVEDZ doi: 10.46594/9785423501099
7. Chalouhi G.E., Bernardi V., Gueneuc A., et al. Evaluation of trainees' ability to perform obstetrical ultrasound using simulation: challenges and opportunities // *Am J Obstet Gynecol*. 2016. Vol. 214, N 4. P. 525–528. doi: 10.1016/j.ajog.2015.10.932
8. Hani S., Chalouhi G., Lakissian Z., Sharara-Chami R. Introduction of Ultrasound Simulation in Medical Education: Exploratory Study // *JMIR Med Educ*. 2019. Vol. 5, N 2. P. 13568. doi: 10.2196/13568
9. Овсянникова Л.С., Шунькова С.А., Кесплери Э.В. Значение симуляционных технологий в повышении качества подготовки специалистов ультразвуковой диагностики // VI Международная (76 Всероссийская) научно-практическая конференция «Актуальные вопросы современной медицинской науки и здравоохранения». 2021. Т. 3. С. 642–645.
10. Freundt P., Nourkami-Tutdibi N., Tutdibi E., et al. Controlled Prospective Study on the Use of Systematic Simulator-Based

Authors' contribution. All authors made a substantial contribution to the conception of the work, acquisition, analysis, interpretation of data for the work, drafting and revising the work, final approval of the version to be published and agree to be accountable for all aspects of the work. V.A. Vasiliev — concept and design of the study, data analysis, writing the text of the article; S.N. Kondrichina — collection and processing of materials.

- Training with a Virtual, Moving Fetus for Learning Second-Trimester Scan: FESIM III // *Ultraschall Med*. 2023. Vol. 44, N 4. P. e199–e205. doi: 10.1055/a-1984-8320
11. Hatzl J., Böckler D., Hartmann N., et al. Mixed reality for the assessment of aortoiliac anatomy in patients with abdominal aortic aneurysm prior to open and endovascular repair: Feasibility and interobserver agreement // *Vascular*. 2023. Vol. 31, N 4. P. 644–653. doi: 10.1177/17085381221081324
 12. Kukla P., Maciejewska K., Strojna I., et al. Extended Reality in Diagnostic Imaging—A Literature Review // *Tomography*. 2023. Vol. 9, N 3. P. 1071–1082. doi: 10.3390/tomography9030088
 13. Васильев В.А., Васильева А.З. 3D/4D анатомическая навигация в виртуальных симуляторах ультразвукового исследования // Актуальные вопросы фундаментальной и клинической морфологии: Материалы Международной научно-практической конференции, Тверь, 14 октября 2022 года. 2022. С. 101–105. EDN: TWYHTL
 14. Bernstein I.H. Likert Scale Analysis. Elsevier, 2005. doi: 10.1016/B0-12-369398-5/00104-3
 15. Dietrich C.F., Lucius C., Nielsen M.B., et al. The ultrasound use of simulators, current view, and perspectives: Requirements and technical aspects (WFUMB state of the art paper) // *Endosc Ultrasound*. 2023. Vol. 12, N 1. P. 38–49. doi: 10.4103/EUS-D-22-00197
 16. Almestehi M., Alomaim W., Rainford L., et al. Role of the virtual reality simulator (ScanTrainer) as a multidisciplinary training tool in transvaginal ultrasound: A systematic review and narrative synthesis // *Radiography (Lond)*. 2019. Vol. 25, N 3. P. 260–268. doi: 10.1016/j.radi.2018.12.009
 17. Pezel T., Dreyfus J., Mouhat B., et al. Effectiveness of Simulation-Based Training on Transesophageal Echocardiography Learning: The SIMULATOR Randomized Clinical Trial // *JAMA Cardiol*. 2023. Vol. 8, N 3. P. 248–256. doi: 10.1001/jamacardio.2022.5016
 18. Tolsgaard M.G., Todsén T., Sørensen J.L., et al. International multispecialty consensus on how to evaluate ultrasound competence: a Delphi consensus survey // *PLoS One*. 2013. Vol. 8, N 2. P. e57687. doi: 10.1371/journal.pone.0057687

REFERENCES

1. Meller G. A typology of simulators for medical education. *J Digit Imaging*. 1997;10(Suppl. 1):194–196. doi: 10.1007/BF03168699
2. Gaba DM. The future vision of simulation in health care. *Quality and Safety in Health Care*. 2004;13(Suppl. 1):2–10. doi: 10.1136/qshc.2004.009878
3. Alinier G. A typology of educationally focused medical simulation tools. *Medical Teacher*. 2007;29(8):243–250. doi: 10.1080/01421590701551185
4. Gorshkov MD, Nikitenko AI. Review of russian and world experience: usage of virtual simulators in training of endosurgeons. *Virtual'nye tekhnologii v meditsine*. 2009;1(1):15–18. EDN: QBAVGC doi: 10.46594/2687-0037_2009_1_18
5. Gorshkov MD, Fedorov AV. Classification of the simulation equipment. *Virtual'nye tekhnologii v meditsine*. 2012;2(8):23–35. EDN: BJWHJB doi: 10.46594/2687-0037_2012_2_21
6. Svistunov AA, editor. *Simulation training in medicine*. Moscow: Sechenov University Publishing; 2013. (In Russ). EDN: XVVEDZ doi: 10.46594/9785423501099
7. Chalouhi GE, Bernardi V, Gueneuc A, et al. Evaluation of trainees' ability to perform obstetrical ultrasound using simulation: challenges

and opportunities. *Am J Obstet Gynecol.* 2016;214(4):525–528. doi: 10.1016/j.ajog.2015.10.932

8. Hani S, Chalouhi G, Lakissian Z, Sharara-Chami R. Introduction of Ultrasound Simulation in Medical Education: Exploratory Study. *JMIR Med Educ.* 2019;5(2):13568. doi: 10.2196/13568

9. Ovsianikova LS, Shunkova SA, Kespleri EV. The importance of simulation technologies in improving the quality of training of specialists in ultrasound diagnostics. *VI International (76 All-Russian) Scientific and Practical Conference "Topical Issues of Modern Medical Science and Public Health".* 2021;3:642–645.

10. Freundt P, Nourkami-Tutdibi N, Tutdibi E, et al. Controlled Prospective Study on the Use of Systematic Simulator-Based Training with a Virtual, Moving Fetus for Learning Second-Trimester Scan: FESIM III. *Ultraschall Med.* 2023;44(4):e199–e205. doi: 10.1055/a-1984-8320

11. Hatzl J, Böckler D, Hartmann N, et al. Mixed reality for the assessment of aortoiliac anatomy in patients with abdominal aortic aneurysm prior to open and endovascular repair: Feasibility and interobserver agreement. *Vascular.* 2023;31(4):644–653. doi: 10.1177/17085381221081324

12. Kukla P, Maciejewska K, Strojna I, et al. Extended Reality in Diagnostic Imaging-A Literature Review. *Tomography.* 2023;9(3):1071–1082. doi: 10.3390/tomography9030088

13. Vasilev VA, Vasileva AE. 3D/4D anatomical navigation in virtual ultrasound simulators. *Actual issues of fundamental and clinical morphology: Proceedings of the International Scientific and Practical Conference, Tver, October 14, 2022.* 2022:101–105. EDN: TWYHTL

14. Bernstein IH. *Likert Scale Analysis.* Elsevier; 2005. doi: 10.1016/B0-12-369398-5/00104-3

15. Dietrich CF, Lucius C, Nielsen MB, et al. The ultrasound use of simulators, current view, and perspectives: Requirements and technical aspects (WFUMB state of the art paper). *Endosc Ultrasound.* 2023;12(1):38–49. doi: 10.4103/EUS-D-22-00197

16. Almestehi M, Alomaim W, Rainford L, et al. Role of the virtual reality simulator (ScanTrainer) as a multidisciplinary training tool in transvaginal ultrasound: A systematic review and narrative synthesis. *Radiography (Lond).* 2019;25(3):260–268. doi: 10.1016/j.radi.2018.12.009

17. Pezel T, Dreyfus J, Mouhat B, et al. Effectiveness of Simulation-Based Training on Transesophageal Echocardiography Learning: The SIMULATOR Randomized Clinical Trial. *JAMA Cardiol.* 2023;8(3):248–256. doi: 10.1001/jamacardio.2022.5016

18. Tolsgaard MG, Todsén T, Sørensen JL, et al. International multispecialty consensus on how to evaluate ultrasound competence: a Delphi consensus survey. *PLoS One.* 2013;8(2):e57687. doi: 10.1371/journal.pone.0057687

ОБ АВТОРАХ

* **Васильев Валерий Анатольевич**, канд. мед. наук, доцент; адрес: Россия, 185910, г. Петрозаводск, пр. Ленина, 33; ORCID: 0000-0001-7164-4274; eLibrary SPIN: 3582-0940; e-mail: valerij-vasiljev@list.ru

Кондричина Светлана Николаевна, канд. мед. наук, доцент; ORCID: 0000-0001-8472-9146; e-mail: konsvet12@gmail.com

AUTHORS' INFO

* **Valeri. A. Vasilev**, MD, Cand. Sci. (Medicine), Assistant Professor; address: 33 Lenin Ave, Petrozavodsk, 185910, Russia; ORCID: 0000-0001-7164-4274; eLibrary SPIN: 3582-0940; e-mail: valerij-vasiljev@list.ru

Svetlana. N. Kondrichina, MD, Cand. Sci. (Medicine), Assistant Professor; ORCID: 0000-0001-8472-9146; e-mail: konsvet12@gmail.com

* Автор, ответственный за переписку / Corresponding author

DOI: <https://doi.org/10.17816/DD623995>

Применение технологии машинного обучения для прогнозирования оптической силы интраокулярных линз: генерализация диагностических данных

А.А. Арзамасцев^{1, 2}, О.Л. Фабрикантов², Н.А. Зенкова³, С.В. Беликов²¹ Воронежский государственный университет, Воронеж, Россия;² Национальный медицинский исследовательский центр «Межотраслевой научно-технический комплекс «Микрохирургия глаза» имени академика С.Н. Федорова», Тамбов, Россия;³ Тамбовский государственный университет имени Г.Р. Державина, Тамбов, Россия

АННОТАЦИЯ

Обоснование. Имплантация современных интраокулярных линз позволяет офтальмологам эффективно решать задачи хирургической реабилитации пациентов с катарактой. Степень улучшения зрительных функций пациента напрямую связана с точностью предоперационного расчёта оптической силы интраокулярных линз. Для расчёта этого показателя используются такие формулы, как SRK II, SRK/T, Hoffer-Q, Holladay II, Haigis, Barrett. Все они хорошо работают для «среднего пациента», однако не являются в достаточной степени адекватными на границах диапазонов входных переменных.

Цель — изучение возможности использования математических моделей, полученных в результате глубокого обучения искусственных нейронных сетей, для генерализации данных и прогнозирования оптической силы современных интраокулярных линз.

Материалы и методы. Обучение моделей, основанных на искусственных нейронных сетях, проводилось на масштабных выборках, в том числе на обезличенных данных пациентов офтальмологической клиники. Данные, предоставленные в 2021 году врачом-офтальмологом К.К. Сырых, отражают результаты как предоперационных, так и послеоперационных наблюдений за пациентами. Исходный файл, использованный для построения модели, основанной на искусственной нейронной сети, включал 455 записей (26 столбцов входных факторов и один столбец выходного фактора) при расчёте интраокулярных линз (дтпр). Для удобного построения моделей использовали программу-симулятор, ранее разработанную авторами.

Результаты. Полученные модели, в отличие от традиционно используемых формул, в гораздо большей степени отражают региональную специфику пациентов. Они также позволяют переобучать и оптимизировать структуру модели на основе вновь поступающих данных, что позволяет учитывать нестационарность объекта. Отличительной особенностью таких моделей, основанных на искусственных нейронных сетях, по сравнению с известными формулами, широко используемыми в хирургическом лечении катаракты, является возможность учёта значительного числа регистрируемых входных величин. Это позволило снизить среднюю относительную погрешность расчётов оптической силы интраокулярных линз с 10–12% до 3,5%.

Заключение. Данное исследование показывает принципиальную возможность генерализации значительного количества эмпирических данных по расчёту оптической силы интраокулярных линз с использованием глубокого обучения моделей искусственных нейронных сетей, которые имеют значительно большее количество входных переменных, чем при использовании традиционных формул и методов. Полученные результаты позволяют построить интеллектуальную экспертную систему с динамическим поступлением новых данных и поэтапным переобучением моделей.

Ключевые слова: искусственный интеллект; медицинские данные; выборка; машинное обучение; интраокулярные линзы.

Как цитировать:

Арзамасцев А.А., Фабрикантов О.Л., Зенкова Н.А., Беликов С.В. Применение технологии машинного обучения для прогнозирования оптической силы интраокулярных линз: генерализация диагностических данных // Digital Diagnostics. 2024. Т. 5, № 1. С. 53–63. DOI: <https://doi.org/10.17816/DD623995>

DOI: <https://doi.org/10.17816/DD623995>

Machine-learning technology for predicting intraocular lens power: Diagnostic data generalization

Alexander A. Arzamastsev^{1, 2}, Oleg L. Fabrikantov², Natalia A. Zenkova³, Sergey V. Belikov²

¹ Voronezh State University, Voronezh, Russia;

² The S. Fyodorov Eye Microsurgery Federal State Institution, Tambov, Russia;

³ Derzhavin Tambov State University, Tambov, Russia

ABSTRACT

BACKGROUND: The implantation of recent intraocular lens (IOLs) allows ophthalmologists to effectively solve the surgical rehabilitation problems of patients with cataracts. The degree of improvement in the patient's visual function is directly dependent on the accuracy of the preoperative calculation of the optical IOL power. The most famous formulas used to calculate this indicator include SRK II, SRK/T, Hoffer-Q, Holladay II, Haigis, and Barrett. All these work well for an "average patient"; however, they are not adequate at the boundaries of input variable ranges.

AIM: To examine the possibility of using mathematical models obtained by deep learning of artificial neural network (ANN) models to generalize data and predict the optical power of modern IOLs.

MATERIALS AND METHODS: ANN models were trained on large-scale samples, including depersonalized data for patients in the ophthalmology clinic. Data provided in 2021 by ophthalmologist K.K. Syrykh reflect the results of both preoperative and postoperative observations of patients. The source file used to build the ANN model included 455 records (26 columns of input factors and one column for the output factor) for calculating IOL (diopters). To conveniently build ANN models, a simulator program previously developed by the authors was used.

RESULTS: The resulting models, in contrast to the traditionally used formulas, reflect the regional specificity of patients to a much greater extent. They also make it possible to retrain and optimize the structure based on newly received data, which allows us to consider the nonstationarity of objects. A distinctive feature of such ANN models in comparison with the well-known formulas SRK II, SRK/T, Hoffer-Q, Holladay II, Haigis, and Barrett, which are widely used in surgical cataract treatment, is their ability to consider a significant number of recorded input quantities, which reduces the mean relative error in calculating the optical IOL power from 10%–12% to 3.5%.

CONCLUSIONS: This study reveals the fundamental possibility of generalizing a significant amount of empirical data on calculating the optical IOL power using training ANN models that have a significantly larger number of input variables than those obtained using traditional formulas and methods. The results obtained allow the construction of an intelligent expert system with a continuous flow of new data from a source and a step-by-step retraining of ANN models.

Keywords: artificial intelligence; medical data; dataset; machine learning; intraocular lenses.

To cite this article:

Arzamastsev AA, Fabrikantov OL, Zenkova NA, Belikov SV. Machine-learning technology for predicting intraocular lens power: Diagnostic data generalization. *Digital Diagnostics*. 2024;5(1):53–63. DOI: <https://doi.org/10.17816/DD623995>

Submitted: 28.11.2023

Accepted: 24.01.2024

Published online: 13.03.2024

DOI: <https://doi.org/10.17816/DD623995>

将机器学习技术应用于眼内镜片光学倍率的预测：诊断数据的归纳

Alexander A. Arzamastsev^{1,2}, Oleg L. Fabrikantov², Natalia A. Zenkova³, Sergey V. Belikov²¹ Voronezh State University, Voronezh, Russia;² The S. Fyodorov Eye Microsurgery Federal State Institution, Tambov, Russia;³ Derzhavin Tambov State University, Tambov, Russia

摘要

论证。现代眼内镜片的植入使眼科医生能够有效解决白内障患者的手术康复难题。患者视觉功能的改善程度与术前计算眼内镜片光学倍率的准确性直接相关。SRK II、SRK/T、Hoffer-Q、Holladay II、Haigis、Barrett等公式都被用来计算这一指数。所有这些公式对于“中等症患者”来说都很有效。但是，在输入变量范围的极端情况下，它们就不够充分。

目的。本研究的目的是探索使用人工神经网络深度学习衍生的数学模型来归纳数据并预测现代眼内镜片光学倍率的可能性。

材料与方法。基于人工神经网络的模型训练是在大规模样本上进行的，包括来自眼科诊所患者的匿名数据。这些数据由眼科医生K. K. 谢雷赫于2021年提供。这些数据反映了患者术前和术后的观察结果。用于建立基于人工神经网络模型的源文件包括455条记录（26列输入因子和1列输出因子），被用于计算眼内镜片（屈光度）。为了方便地建立模型，使用了先前开发的一个模拟程序。

结果。与传统的公式相比，所获得的模型更能反映患者的区域特性。它们还可以根据新获得的数据重新训练和优化模型结构。这样就有可能考虑到对象的非稳定性。与白内障手术中广泛使用的已知公式相比，这种基于人工神经网络模型的一个显著特点是可以考虑大量记录的输入值。这使得计算眼内镜片光学倍率的平均相对误差可以从10–12%降低到3.5%。

结论。本项研究表明，使用人工神经网络模型的深度学习来归纳大量经验数据来计算人工晶状体的光学强度是基本可行的。与使用传统公式和方法相比，这种网络的输入变量数量要大得多。所得结果使得构建新数据动态输入、模型逐步再训练的智能专家系统成为可能。

关键词：人工智能；医疗数据；样本；机器学习；眼内镜片。

引用本文：

Arzamastsev AA, Fabrikantov OL, Zenkova NA, Belikov SV. 将机器学习技术应用于眼内镜片光学倍率的预测：诊断数据的归纳. *Digital Diagnostics*. 2024;5(1):53–63. DOI: <https://doi.org/10.17816/DD623995>

收到: 28.11.2023

接受: 24.01.2024

发布日期: 13.03.2024

ОБОСНОВАНИЕ

Имплантация современных интраокулярных линз (ИОЛ) позволяет офтальмологам эффективно решать задачи хирургической реабилитации пациентов с катарактой. Однако степень улучшения зрительных функций пациента напрямую связана с точностью предоперационного расчёта оптической силы ИОЛ. В связи с этим в офтальмологии используются различные формулы для расчёта этого показателя. К наиболее известным относятся формулы SRK II, SRK/T, Hoffer-Q, Holladay II, Haigis, Barrett [1–7]. Все они хорошо работают для «среднего пациента», но не являются в достаточной степени адекватными на границах диапазонов входных переменных. Есть у них и другие недостатки: во-первых, они не учитывают нестационарность объектов и не позволяют менять настройки при вводе новых эмпирических данных, как, например, при локализации модели; во-вторых, количество учитываемых входных факторов оказывается явно недостаточным. Эти обстоятельства приводят к множеству локальных поправок к приведённым формулам и их постоянной адаптации [2, 8].

Одна из первых формул для расчёта оптической силы ИОЛ, основанная на законах оптики и данных схематического глаза, принадлежит выдающемуся российскому офтальмологу С.Н. Фёдорову (1967) [1, 2]. В последующие годы, вплоть до настоящего времени, наиболее часто для расчёта оптической силы ИОЛ в офтальмологической практике использовались формулы SRK/T, SRK II, Hoffer-Q, Holladay II, Haigis и Barrett [3–7]. Самые ранние формулы для расчёта оптической силы ИОЛ за рубежом появились в конце 1970-х — начале 1980-х гг. Они были либо теоретическими, либо регрессионными. В предпочтениях хирургов преобладали регрессионные формулы, одна из самых успешных — SRK, разработанная D.R. Sanders, J.A. Retzlaff и M.C. Kraff [3–5].

В настоящее время наблюдается беспрецедентное развитие систем искусственного интеллекта на основе искусственных нейронных сетей (ИНС), которые путём глубокого обучения с использованием значительных по объёмам массивов эмпирических данных позволяют строить адекватные модели практически в любой предметной области, в том числе в биологии и медицине [9–12]. Кроме того, современные офтальмологические центры за последние десятилетия создали хранилища данных о пациентах, включающие десятки и сотни тысяч записей оцифрованных показателей.

В этой ситуации можно предполагать, что радикальным методом решения проблемы предоперационного расчёта ИОЛ стало бы построение интеллектуальной экспертной системы, ядром которой была бы математическая модель, построенная с помощью ИНС (ИНС-модель). Такая модель могла бы обучаться на основе поступающих из хранилища данных, что позволило бы учесть значительно большее число значимых входных факторов

и региональную специфику пациентов, по сравнению с известными формулами. Поэтапное переучивание ИНС-модели на вновь поступающих из хранилища данных, а при необходимости и модификация её структуры обеспечили бы её адаптивность и сняли проблему учёта нестационарности объекта и локализации модели.

Первым этапом построения такой интеллектуальной экспертной системы является решение принципиального вопроса о генерализации (возможности обобщения) эмпирических данных значительного числа пациентов с помощью ИНС-модели, выявление значимых наблюдаемых входных факторов и сравнение адекватности такой модели с известными формулами [1–7].

ЦЕЛИ

Изучить возможности генерализации значительного количества эмпирических данных по расчёту ИОЛ, полученных в одном из офтальмологических центров России в результате лечения пациентов, с использованием глубокого обучения ИНС-моделей; выявить наиболее значимые наблюдаемые входные факторы, оказывающие существенное влияние на погрешность предоперационного расчёта ИОЛ; сравнить погрешности расчётов по ИНС-моделям с известными формулами.

Погрешности расчёта оптической силы интраокулярных линз

Ранее мы сравнивали погрешности в использовании некоторых формул на основе значительного количества эмпирических данных, предоставленных в обезличенном виде Тамбовским филиалом Федерального государственного автономного учреждения «Национальный медицинский исследовательский центр “Межотраслевой научно-технический комплекс “Микрохирургия глаза» имени академика С.Н. Фёдорова”» Министерства здравоохранения Российской Федерации [13]. Исходные данные были получены в конце 2014 года. Первоначальное количество записей составило 28 940. Каждая запись содержала следующие параметры:

- анонимный номер пациента;
- дата операции;
- торговая марка и оптическая сила имплантированной ИОЛ;
- возраст пациента;
- длина глаза;
- требуемая оптическая сила ИОЛ для коррекции аномалий рефракции и астигматизма (сфера и цилиндр);
- дополнительная информация, связанная с положением ИОЛ в глазу.

Количество обработанных записей составило 11 701. При этом 17 239 записей не были обработаны в связи с отсутствием параметров линзы или некорректностью данных в полях.

Формулы Haigis, Holladay, SRK II и SRK/T рассматривались как наиболее близкие к эмпирическим данным.

Значения средних относительных погрешностей при расчёте ИОЛ представлены в табл. 1. На рис. 1 показана корреляционная зависимость требуемой и рассчитанной оптической силы ИОЛ по данным формулам. При вычислении средней оптической силы ИОЛ все формулы дают результаты, близкие к требуемым, однако при крайних значениях наблюдается значительный разброс относительно требуемых величин.

Так, существенное расхождение значений наблюдается в угле наклона зависимости относительно диагонали, соответствующей точным расчётам (рис. 1, *a, b, d*). Во всех исследованных формулах в качестве входных величин используются три параметра: длина глаза в мм (*L*), среднее арифметическое меридианов в мм (*K*) и глубина передней

камеры как параметр линзы. Это обстоятельство неизбежно предполагает наличие других факторов (возможно, ненаблюдаемых). Их воздействие на оптическую силу ИОЛ обусловило перечисленные особенности расчётов.

Таблица 1. Сравнение погрешностей расчёта оптической силы интраокулярных линз, полученных при использовании различных формул

Формула	Средняя относительная погрешность расчёта интраокулярных линз, %
Формула Haigis	15,6
Формула Holladay	13,4
Формула SRK II	11,7
Формула SRK/T	12,5




Рис. 1. Корреляционная зависимость требуемой оптической силы интраокулярных линз (по горизонтальной оси) и их рассчитанной оптической силы (по вертикальной оси согласно формулам) для 11 701 пациента: *a* — Haigis; *b* — Holladay; *c* — SRK II; *d* — SRK/T. ИОЛ — интраокулярные линзы. Коэффициенты корреляции представлены на графиках.

В том же исследовании [13] мы представили оптимизированную регрессионную формулу, полученную путём минимизации средней квадратичной погрешности с помощью методов нелинейного программирования для 11 701 пациента. Нам удалось снизить среднюю относительную погрешность до 10,6% за счёт введения четвертой переменной. Это означает, что нужно учитывать дополнительные входные переменные и, в идеале, всю необходимую информацию о пациенте. В этом случае оптимальным инструментом для прогнозирования оптической силы ИОЛ будет использование ИНС-моделей.

Наиболее близким к нашей работе является исследование Т. Yamauchi и соавт. [14], направленное на описание использования машинного обучения для прогнозирования послеоперационной рефракции при удалении катаракты и сравнения точности модели с традиционными формулами при расчёте оптической силы ИОЛ. Обучающая выборка включала данные 2010 пациентов (3331 глаза). Коэффициенты модели оптимизировались с помощью обучения по данным. Затем возникновение послеоперационной рефракции авторы прогнозировали с использованием общепринятых формул: SRK/T, Haigis, Holladay II, Hoffer-Q и Barrett Universal II formula (BU-II). Абсолютные погрешности некоторых методов машинного обучения были ниже, чем при вычислении по формулам. Однако статистически значимой разницы не наблюдалось.

Полученные результаты являются, на наш взгляд, ожидаемыми, так как авторы не использовали дополнительных входных параметров, а машинное обучение и метод наименьших квадратов, обычно используемый

при параметрической идентификации формул, как правило, приводят к сопоставимым результатам. В настоящем исследовании мы анализируем возможности использования ИНС-моделей для прогнозирования оптической силы ИОЛ с использованием гораздо большего числа входных параметров.

Работа над расчётами ИОЛ продолжается в связи с:

- необходимостью уменьшения погрешностей;
- появлением данных о новых факторах, которые не учитывались в предыдущих расчётах (ранее учитывались только 4 входных фактора по сравнению с нынешними 26);
- желанием разработать адаптивную модель расчёта ИОЛ, которая могла бы учитывать возможную нестационарность при поступлении новых данных;
- стремлением создать экспертную систему с динамическим поступлением данных и её поэтапным обучением с использованием ИНС-моделей.

МАТЕРИАЛЫ И МЕТОДЫ

В 2021 году офтальмолог К.К. Сырых представил первичные данные в виде обезличенных результатов предоперационных и послеоперационных обследований пациентов. Исходный файл данных, использованный для построения ИНС-модели, включал 455 записей: 26 столбцов входных факторов и один столбец — выходной фактор — расчёт ИОЛ (дптр). Для удобства работы входные параметры обозначены через x_1-x_{26} , выходной параметр — через Y . Входные переменные представлены в табл. 2.

Таблица 2. Входные параметры для построения модели, основанной на искусственной нейронной сети

Параметр	Значение	Параметр	Значение
x_1	пол	x_{14}	длина глаза (оптическая биометрия, мм)
x_2	острота зрения без коррекции до операции	x_{15}	острота зрения без коррекции после операции
x_3	сферический компонент рефракции по данным визометрии до операции	x_{16}	сферический компонент рефракции по данным визометрии после операции
x_4	цилиндрический компонент рефракции по данным визометрии до операции	x_{17}	цилиндрический компонент рефракции по данным визометрии после операции
x_5	ось цилиндра по данным визометрии до операции	x_{18}	ось цилиндра по данным визометрии после операции
x_6	острота зрения с коррекцией до операции	x_{19}	острота зрения с коррекцией после операции
x_7	ось сильного меридиана роговицы до операции	x_{20}	ось сильного меридиана роговицы после операции
x_8	рефракция сильного меридиана роговицы до операции	x_{21}	рефракция сильного меридиана роговицы после операции
x_9	ось слабого меридиана роговицы до операции	x_{22}	ось слабого меридиана роговицы после операции
x_{10}	рефракция слабого меридиана роговицы до операции	x_{23}	рефракция слабого меридиана роговицы после операции
x_{11}	сферический компонент рефракции по данным рефрактометрии до операции	x_{24}	сферический компонент рефракции по данным рефрактометрии после операции
x_{12}	цилиндрический компонент рефракции по данным рефрактометрии до операции	x_{25}	цилиндрический компонент рефракции по данным рефрактометрии после операции
x_{13}	ось цилиндра по данным рефрактометрии до операции	x_{26}	ось цилиндра по данным рефрактометрии после операции

Для удобства построения ИНС-моделей использовалась программа-симулятор, ранее разработанная авторами [15].

РЕЗУЛЬТАТЫ

Одним из наиболее сложных вопросов при разработке ИНС-моделей является принятие гипотезы о структуре (архитектуре) сети.

Известно, что при использовании теорем А.Н. Колмогорова [16, 17] часто получается структура ИНС-модели, являющейся избыточной. Как правило, такая модель хорошо представляет выходную переменную в узловых точках, но обладает слабой прогностической способностью.

В работе [18] мы предложили конструктивный алгоритм, позволяющий увеличивать количество нейронов в скрытом слое и число скрытых слоёв до достижения определённых условий. При этом используются линейные, квадратичные, кубические и другие передаточные функции нейронов, а не общепринятые сигмоидальные. Наш подход основан на разложении функции нескольких переменных в ряд Тейлора (1)–(2). При разложении функции большого числа переменных необходимо сначала ввести дифференциальный оператор:

$$T^k = \sum_{m=1}^n (x^{(m)} - x_0^{(m)})^k \frac{\partial^k}{\partial x_k^{(m)}} \quad (1)$$

Разложение функции $f(x^{(1)}, x^{(2)}, \dots, x^{(n)})$ в ряд Тейлора имеет следующий вид:

$$\begin{aligned} f(x^{(1)}, x^{(2)}, \dots, x^{(n)}) = \\ = f(x_0^{(1)}, x_0^{(2)}, \dots, x_0^{(n)}) + \\ + \sum_k^p \frac{T^k(x^{(1)}, x^{(2)}, \dots, x^{(n)})}{k!} + \\ + R_p(x^{(1)}, x^{(2)}, \dots, x^{(n)}) \end{aligned} \quad (2)$$

Такой подход позволяет получать нейронные сети с относительно простой архитектурой, обладающие хорошими аппроксимирующими (генерализующими) и прогностическими способностями.

ИНС-модель, построенная в соответствии с формулами (1) и (2), имеет 4 слоя:

- 1) слой входных нейронов;
- 2) функциональный скрытый слой, соответствующий нескольким членам ряда Тейлора;
- 3) суммирующий скрытый слой;
- 4) выходной слой.

Функциональный скрытый слой содержит нейроны с передаточными функциями, соответствующими членам

ряда Тейлора: линейными (первый порядок), квадратичными (второй порядок) и кубическими (третий порядок). Суммирующий скрытый слой содержит один линейный нейрон, его основная функция — вычисление суммы нескольких членов ряда и прибавление к ним постоянного значения. Такая архитектура позволила добиться приемлемой точности ИНС-модели.

В качестве функции потерь использовали сумму квадратов отклонений модельных и эмпирических значений.

При обучении моделей на основе эмпирических данных были выбраны следующие методы оптимизации: метод стохастического градиента, простой градиентный метод и безградиентные методы покоординатного спуска Гаусса–Зейделя и Монте-Карло, которые использовались в интерактивном режиме.

Обучение ИНС-модели на основе данных по ИОЛ начали с сети, представляющей собой 26 входных нейронов и один линейный нейрон в скрытом слое. Такая конструкция соответствовала свободному и первому членам в формулах (1) и (2). Учитывая рекомендации предыдущих исследований [8–11], процесс обучения модели проводили на 70% всей выборки, прогностическую способность ИНС-модели оценивали на оставшихся 30% выборки. Данные для обучения и проверки адекватности модели выбирали из общей таблицы в произвольном порядке с равномерным распределением случайных величин.

Результаты обучения этой простой модели показаны на рис. 2. Истинную оптическую силу данного типа ИОЛ для получения эметропии в каждом случае определяли как сумму оптической силы имплантированной ИОЛ




Рис. 2. Корреляция расчётных (Y_{mod}) и эмпирических данных (Y_{tab}) для модели первого порядка. Коэффициент парной корреляции — 0,84; средняя относительная погрешность — 11,9%.

и результирующей рефракционной погрешности. Погрешность рефракции рассчитывали с помощью ретроспективного анализа в период от 1 до 6 месяцев после операции.

По уровню средней относительной погрешности полученные результаты сопоставимы с классическими формулами, однако в данном случае для прогнозирования оптической силы ИОЛ мы использовали линейную функцию 26 переменных. При этом коэффициент парной корреляции расчётных и эмпирических данных составил 0,71, а средняя относительная погрешность — 11,9%.

Коэффициенты синаптических связей для каналов линейной модели представляют собой чувствительность каналов, значения которых могут быть использованы для оценки степени их влияния на выходную переменную. Численные эксперименты показали, что не менее 12–15 входных факторов (доступных офтальмологу) существенно влияют на предоперационные расчёты оптической силы ИОЛ. Следовательно, наши предположения относительно необходимости учёта большего числа входных величин для снижения погрешности расчёта полностью подтвердились. Ясно также, что значительные погрешности классических формул [3–7] тоже могут быть связаны с наличием большего числа входных факторов, которые в этих формулах являются ненаблюдаемыми.

Значения некоторых факторов (например, x_{16} , x_{21} , x_{23} и x_{24}) становятся известны только после операции. Однако они хорошо коррелируют с аналогичными факторами до операции, их значения поэтому хорошо предсказуемы.

Следуя нашему алгоритму [18], мы изменили структуру ИНС-модели таким образом, чтобы наряду с линейным

нейроном в скрытом слое присутствовал и квадратичный нейрон. Обучение такой ИНС-модели аналогичными численными методами нелинейного программирования позволило снизить среднюю относительную погрешность до 5%. Таким образом, предыдущие результаты удалось улучшить в 2 раза. При этом коэффициент парной корреляции составил 0,97, а средняя относительная погрешность — 4,8% (рис. 3).

Следуя указанной логике, мы также построили ИНС-модель третьего порядка, содержащую в скрытом слое нейроны с линейной, квадратичной и кубической передаточными функциями. Обучение такой ИНС-модели аналогичными численными методами нелинейного программирования позволило снизить среднюю относительную погрешность до уровня 3,5%, при коэффициенте парной корреляции 0,98 (рис. 4).

Необходимо отметить, что число степеней свободы данной ИНС-модели, равное количеству синаптических связей ($26 \times 3 + 3 = 81$), существенно меньше, чем количество записей в обучающей выборке. Это обстоятельство указывает на хорошую генерализуемость эмпирических данных по расчёту оптической силы ИОЛ с использованием ИНС-моделей.

В табл. 3 приведены результаты сравнения различных методов расчёта оптической силы ИОЛ. Таким образом, при использовании ИНС-моделей и значительно большего числа входных переменных средняя относительная погрешность расчётов может быть снижена более чем в два раза по сравнению с традиционными методами.




Рис. 3. Корреляция расчётных (Y_{mod}) и эмпирических данных (Y_{tab}) модели второго порядка. Коэффициент парной корреляции — 0,97; средняя относительная погрешность — 4,8%.




Рис. 4. Корреляция расчётных (Y_{mod}) и эмпирических данных (Y_{tab}) для модели третьего порядка. Коэффициент парной корреляции — 0,98; средняя относительная погрешность — 3,5%.

Таблица 3. Результаты сравнения средних относительных погрешностей расчётов оптической силы интраокулярных линз и коэффициентов корреляции расчётных и эмпирических данных для различных методов

Формула или ИНС-модель	Средняя относительная погрешность, %	Коэффициент корреляции расчётных и эмпирических данных
Формула Haigis	15,6	0,85
Формула Holladay	13,4	0,86
Формула SRK II	11,7	0,86
Формула SRK/T	12,5	0,86
Линейная ИНС-модель	11,9	0,84
Нелинейная ИНС-модель второго порядка	4,8	0,98
Нелинейная ИНС-модель третьего порядка	3,5	0,99

Примечание. ИНС — искусственная нейронная сеть.

ОБСУЖДЕНИЕ

Следующим этапом исследований в этом направлении должен быть сбор значительно большего числа обезличенных данных пред- и послеоперационного обследования пациентов, так как методы глубокого машинного обучения нуждаются в существенных по объёму обучающих выборках, после чего модели должны проходить процедуру валидации на тестовых выборках [11–14]. Если в системе имеются ещё и гиперпараметры (параметры, которые должны быть заданы «сверху», и от удачного введения которых существенно зависит решение задачи), то должна использоваться и третья, дополнительная проверочная выборка данных. Наличие таких данных позволит построить интеллектуальную экспертную систему предоперационного расчёта ИОЛ. Некоторые принципы построения такой системы мы уже описывали [19].

ЗАКЛЮЧЕНИЕ

Показана принципиальная возможность генерализации значительного количества эмпирических данных по расчёту оптической силы ИОЛ с использованием глубокого обучения ИНС-моделей, имеющих значительно большее количество входных переменных, чем при использовании традиционных формул и методов. Выявление наиболее значимых наблюдаемых факторов, оказывающих существенное влияние на целевой показатель, и их включение в ИНС-модель позволяют снизить погрешность расчётов более чем в 2 раза. Способность моделей на основе ИНС к хорошей генерализации данных открывает возможности создания интеллектуальной экспертной системы с динамическим поступлением новых данных и поэтапным глубоким машинным обучением интеллектуального ядра. Основной особенностью такой системы по сравнению с использованием традиционных формул расчёта является её адаптивность, позволяющая решать проблемы нестационарности объекта и локализации вследствие наличия в ней обратной связи. В настоящее время разработанная ИНС-модель используется

в режиме ассистента офтальмолога в сочетании с другими инструментами для предоперационного расчёта оптической силы ИОЛ.

ДОПОЛНИТЕЛЬНАЯ ИНФОРМАЦИЯ

Источник финансирования. Авторы заявляют об отсутствии внешнего финансирования при проведении исследования.

Конфликт интересов. Авторы декларируют отсутствие явных и потенциальных конфликтов интересов, связанных с публикацией настоящей статьи.

Вклад авторов. Все авторы подтверждают соответствие своего авторства международным критериям ICMJE (все авторы внесли существенный вклад в разработку концепции, проведение исследования и подготовку статьи, прочли и одобрили финальную версию перед публикацией).

Наибольший вклад распределён следующим образом: А.А. Арзамасцев — концепция исследования, обработка данных, расчёты на основе ИНС-моделей, написание рукописи, редактирование рукописи; О.Л. Фабрикантов — концепция исследования, анализ литературы, редактирование рукописи; Н.А. Зенкова — обработка данных, анализ литературы, редактирование рукописи; С.В. Беликов — подготовка датасета, поиск публикаций.

ADDITIONAL INFO

Funding source. This study was not supported by any external sources of funding.

Competing interests. The authors declare that they have no competing interests.

Authors' contribution. All authors made a substantial contribution to the conception of the work, acquisition, analysis, interpretation of data for the work, drafting and revising the work, final approval of the version to be published and agree to be accountable for all aspects of the work.

А.А. Arzamastsev — research concept, data processing, writing the manuscript, editing the manuscript; О.Л. Fabrikantov — research concept, literature analysis, editing the manuscript; Н.А. Zenkova — data processing, literature analysis, editing the manuscript; S.V. Belikov — preparing the dataset, searching for publications.

СПИСОК ЛИТЕРАТУРЫ

1. Фёдоров С.Н., Колинко А.И. Методика расчета оптической силы интраокулярной линзы // Вестник офтальмологии. 1967. № 4. С. 27–31.
2. Балашевич Л.И., Даниленко Е.В. Результаты использования формулы С.Н. Фёдорова для расчёта силы заднекамерных интраокулярных линз // Офтальмохирургия. 2011. № 1. С. 34–38. EDN: PXRASV
3. Sanders D.R., Kraff M.C. Improvement of intraocular lens power calculation using empirical data // American Intra-Ocular Implant Society Journal. 1980. Vol. 6. P. 263–267. doi: 10.1016/s0146-2776(80)80075-9
4. Sanders D.R., Retzlaff J.A., Kraff M.C. Comparison of the SRK II formula and other second-generation formulas // Journal of Cataract & Refractive Surgery. 1988. Vol. 14, N 2. P. 136–141. doi: 10.1016/s0886-3350(88)80087-7
5. Sanders D.R., Retzlaff J.A., Kraff M.C. Development of the SRK/T IOL power calculation formula // Journal of Cataract & Refractive Surgery. 1990. Vol. 16, N 3. P. 333–340. doi: 10.1016/s0886-3350(13)80705-5
6. Hoffer K.J. The Hoffer Q formula: a comparison of theoretic and regression formulas // Journal of Cataract & Refractive Surgery. 1993. Vol. 19, N 6. P. 700–712. doi: 10.1016/s0886-3350(13)80338-0
7. Holladay J.T., Prager T.C., Ruiz R.S., et al. A three-part system for refining intraocular lens power calculation // Journal of Cataract & Refractive Surgery. 1988. Vol. 14, N 1. P. 17–24. doi: 10.1016/S0886-3350(88)80059-2
8. Першин К.Б., Пашинова Н.Ф., Цыганков А.Ю., Легких С.Л. Алгоритм выбора формулы для расчета оптической силы ИОЛ при экстремальной миопии // Точка зрения. Восток – Запад. 2016. № 1. С. 64–67. EDN: WHCNPF
9. Будума Н., Локашо Н. Основы глубокого обучения. Создание алгоритмов для искусственного интеллекта следующего поколения. Москва : Манн, Иванов и Фербер, 2020.
10. Фостер Д. Генеративное глубокое обучение. Творческий потенциал нейронных сетей. Санкт-Петербург : Питер, 2020.
11. Рамсундар Б., Истман П., Уолтерс П., Панде В. Глубокое обучение в биологии и медицине. Москва : ДМК Пресс, 2020.
12. Харрисон М. Машинное обучение: карманный справочник. Краткое руководство по методам структурированного машинного обучения на Python. Санкт-Петербург : ООО «Диалектика», 2020.
13. Арзамасцев А.А., Фабрикантов О.Л., Зенкова Н.А., Белосусов Н.К. Оптимизация формул для расчета ИОЛ // Вестник Тамбовского университета. Серия Естественные и технические науки. 2016. Т. 21, № 1. С. 208–213. EDN: VNWHVZ doi: 10.20310/1810-0198-2016-21-1-208-213
14. Yamauchi T., Tabuchi T., Takase K., Masumoto H. Use of a machine learning method in predicting refraction after cataract surgery // Journal of Clinical Medicine. 2021. Vol. 10, N 5. P. 1103. doi: 10.3390/jcm10051103
15. Свидетельство о государственной регистрации программы для ЭВМ № 2012618141/ 07.09.2012. Арзамасцев А.А., Рыков В.П., Крючин О.В. Симулятор искусственной нейронной сети с реализацией модульного принципа обучения.
16. Колмогоров А.Н. О представлении непрерывных функций нескольких переменных суперпозициями непрерывных функций меньшего числа переменных // Доклады Академии наук СССР. 1956. Т. 108, № 2. С. 179–182.
17. Колмогоров А.Н. О представлении непрерывных функций нескольких переменных в виде суперпозиции непрерывных функций одного переменного // Доклады Академии наук СССР. 1957. Т. 114, № 5. С. 953–956.
18. Арзамасцев А.А., Крючин О.В., Азарова П.А., Зенкова Н.А. Универсальный программный комплекс для компьютерного моделирования на основе искусственной нейронной сети с самоорганизацией структуры // Вестник Тамбовского университета. Серия: Естественные и технические науки. 2006. Т. 11, № 4. С. 564–570. EDN: IRMPYX
19. Arzamastsev A.A., Zenkova N.A., Kazakov N.A. Algorithms and methods for extracting knowledge about objects defined by arrays of empirical data using ANN models // Journal of Physics: Conference Series. 2021. doi: 10.1088/1742-6596/1902/1/012097

REFERENCES

1. Fyodorov SN, Kolinko AI. Method of calculating the optical power of an intraocular lens. *The Russian Annals of Ophthalmology*. 1967;(4):27–31. (In Russ).
2. Balashevich LI, Danilenko EV. Results in application of the fyodorov's iol power formula for posterior chamber lenses calculation. *Fyodorov Journal of Ophthalmic Surgery*. 2011;(1):34–38. EDN: PXRASV
3. Sanders DR, Kraff MC. Improvement of intraocular lens power calculation using empirical data. *American Intra-Ocular Implant Society Journal*. 1980;6:263–267. doi: 10.1016/s0146-2776(80)80075-9
4. Sanders DR, Retzlaff JA, Kraff MC. Comparison of the SRK II formula and other second-generation formulas. *Journal of Cataract & Refractive Surgery*. 1988;14(2):136–141. doi: 10.1016/s0886-3350(88)80087-7
5. Sanders DR, Retzlaff JA, Kraff MC. Development of the SRK/T IOL power calculation formula. *Journal of Cataract & Refractive Surgery*. 1990;16(3):333–340. doi: 10.1016/s0886-3350(13)80705-5
6. Hoffer KJ. The Hoffer Q formula: a comparison of theoretic and regression formulas. *Journal of Cataract & Refractive Surgery*. 1993;19(6):700–712. doi: 10.1016/s0886-3350(13)80338-0
7. Holladay JT, Prager TC, Ruiz RS, et al. A three-part system for refining intraocular lens power calculation. *Journal of Cataract & Refractive Surgery*. 1988;14(1):17–24. doi: 10.1016/S0886-3350(88)80059-2
8. Pershin KB, Pashinova NF, Tsygankov AY, Legkhih SL. Choice of IOL Optic Power Calculation Formula in Extremely High Myopia Patients “Excimer” Ophthalmology Centre, Moscow. *Point of view. East - West*. 2016;(1):64–67. EDN: WHCNPF
9. Buduma N, Lokasho N. *Foundations of deep learning. Creating Algorithms for Next Generation Artificial Intelligence*. Moscow: Mann, Ivanov i Ferber; 2020. (In Russ).
10. Foster D. *Generative deep learning. Creative potential of neural networks*. Saint Petersburg: Piter; 2020. (In Russ).
11. Ramsundar B, Istman P, Uolters P, Pande V. *Deep learning in biology and medicine*. Moscow: DMK Press; 2020. (In Russ).
12. Kharrison M. *Machine learning: a pocket guide. A quick guide to structured machine learning methods in Python*. Saint Petersburg: Dialektika LLC; 2020. (In Russ).

13. Arzamastsev AA, Fabrikantov OL, Zenkova NA, Belousov NK. Optimization of Formulae for Intraocular Lenses Calculating. *Tambov University Reports. Series: Natural and Technical Sciences*. 2016;21(1):208–213. EDN: VNWHVZ doi: 10.20310/1810-0198-2016-21-1-208-213
14. Yamauchi T, Tabuchi T, Takase K, Masumoto H. Use of a machine learning method in predicting refraction after cataract surgery. *Journal of Clinical Medicine*. 2021;10(5):1103. doi: 10.3390/jcm10051103
15. Certificate of state registration of the computer program № 2012618141/ 07.09.2012. Arzamastsev AA, Rykov VP, Kryuchin OV. *Artificial neural network simulator with implementation of modular learning principle*. (In Russ).
16. Kolmogorov AN. On the representation of continuous functions of several variables by superpositions of continuous functions of

- fewer variables. *Doklady Akademii nauk SSSR*. 1956;108(2):179–182. (In Russ).
17. Kolmogorov AN. On the representation of continuous functions of several variables as a superposition of continuous functions of one variable. *Doklady Akademii nauk SSSR*. 1957;114(5):953–956. (In Russ).
18. Arzamastsev AA, Kryuchin OV, Azarova PA, Zenkova NA. The universal program complex for computer simulation on the basis of the artificial neuron network with self-organizing structure. *Tambov University Reports. Series: Natural and Technical Sciences*. 2006;11(4):564–570. EDN: IRMPYX
19. Arzamastsev AA, Zenkova NA, Kazakov NA. Algorithms and methods for extracting knowledge about objects defined by arrays of empirical data using ANN models. *Journal of Physics: Conference Series*. 2021. doi: 10.1088/1742-6596/1902/1/012097

ОБ АВТОРАХ

* **Арзамасцев Александр Анатольевич**, д-р техн. наук, профессор;
адрес: Россия, 392000, г. Тамбов, ул. Лаврова, д. 24;
ORCID: 0000-0001-6795-2370;
eLibrary SPIN: 4410-6340;
e-mail: arz_sci@mail.ru

Фабрикантов Олег Львович, д-р мед. наук, профессор;
ORCID: 0000-0003-0097-991X;
eLibrary SPIN: 9675-9696;
e-mail: fabr-mntk@yandex.ru

Зенкова Наталья Александровна, канд. психол. наук, доцент;
ORCID: 0000-0002-2325-1924;
eLibrary SPIN: 2266-4168;
e-mail: natulin@mail.ru

Беликов Сергей Вячеславович;
ORCID: 0000-0002-4254-3906;
eLibrary SPIN: 5553-8398;
e-mail: pvt.leopold@gmail.com

AUTHORS' INFO

* **Alexander A. Arzamastsev**, Dr. Sci. (Engineering), Professor;
address: 24 Lavrova street, 392000 Tambov, Russia;
ORCID: 0000-0001-6795-2370;
eLibrary SPIN: 4410-6340;
e-mail: arz_sci@mail.ru

Oleg L. Fabrikantov, MD, Dr. Sci. (Medicine), Professor;
ORCID: 0000-0003-0097-991X;
eLibrary SPIN: 9675-9696;
e-mail: fabr-mntk@yandex.ru

Natalia A. Zenkova, Cand. Sci. (Psychology), Assistant Professor;
ORCID: 0000-0002-2325-1924;
eLibrary SPIN: 2266-4168;
e-mail: natulin@mail.ru

Sergey V. Belikov, MD;
ORCID: 0000-0002-4254-3906;
eLibrary SPIN: 5553-8398;
e-mail: pvt.leopold@gmail.com

* Автор, ответственный за переписку / Corresponding author

DOI: <https://doi.org/10.17816/DD624022>

Технологии машинного обучения и искусственной нейронной сети в классификации посткератотомической деформации роговицы

Е.К. Цыренжапова¹, О.И. Розанова¹, Т.Н. Юрьева^{1, 2, 3}, А.А. Иванов¹, И.С. Розанов⁴¹ Национальный медицинский исследовательский центр «Межотраслевой научно-технический комплекс «Микрохирургия глаза» имени академика С.Н. Фёдорова», Иркутск, Россия;² Иркутский государственный медицинский университет, Иркутск, Россия;³ Российская медицинская академия непрерывного профессионального образования, Иркутск, Россия;⁴ ООО «Транснефть-Технологии», Иркутск, Россия

АННОТАЦИЯ

Обоснование. Тщательный анализ как оптических, так и анатомических свойств роговицы у пациентов после перенесённой передней радиальной кератотомии приобретает особое значение в выборе оптической силы интраокулярной линзы при хирургическом лечении катаракты и других видах оптической коррекции. Вариабельность клинической картины посткератотомической деформации определяет необходимость разработки её классификации и является важной задачей современной офтальмологии.

Цель — разработать автоматизированную систему классификации посткератотомической деформации роговицы с использованием машинного обучения и искусственной нейронной сети на основе анализа численных значений топографических карт роговицы.

Материалы и методы. В качестве материала использовались обезличенные результаты анализа медицинской документации 250 пациентов в возрасте от 46 до 76 лет (средний возраст — 59,63±5,95 года). Проведён анализ 500 карт рельеф-топографии передней и задней поверхностей роговицы и 3 этапа машинного обучения классификации посткератотомической деформации.

Результаты. I этап — анализ рельеф-топографии передней и задней поверхностей роговицы — позволил зафиксировать численные значения элевации передней и задней поверхности роговицы в трёх кольцевидных зонах. На II этапе в ходе глубокого машинного обучения была выбрана и создана нейросеть прямого распространения. Установлены 8 вспомогательных параметров, описывающих форму передней и задней поверхностей роговицы. III этап сопровождался получением алгоритмов классификации посткератотомической деформации роговицы в зависимости от соотношения тестовой и обучающей выборок, которое варьировало от 75 до 91%.

Заключение. Разработана искусственная нейронная сеть, успешно решающая задачу классификации типов посткератотомической деформации роговицы с точностью 91%. Установлен потенциал для дальнейшего улучшения качества обучения данной нейронной сети. Применение алгоритмов искусственной нейронной сети может стать полезным инструментом автоматической классификации посткератотомической деформации роговицы у пациентов, перенёвших ранее радиальную кератотомию.

Ключевые слова: передняя радиальная кератотомия; искусственный интеллект; машинное обучение; рельеф-топография роговицы.

Как цитировать:

Цыренжапова Е.К., Розанова О.И., Юрьева Т.Н., Иванов А.А., Розанов И.С. Технологии машинного обучения и искусственной нейронной сети в классификации посткератотомической деформации роговицы // Digital Diagnostics. 2024. Т. 5, № 1. С. 64–74. DOI: <https://doi.org/10.17816/DD624022>

DOI: <https://doi.org/10.17816/DD624022>

Machine-learning and artificial neural network technologies in the classification of postkeratotomic corneal deformity

Ekaterina K. Tsyrenzhapova¹, Olga I. Rozanova¹, Tatiana N. Iureva^{1, 2, 3}, Andrey A. Ivanov¹, Ivan S. Rozanov⁴

¹ The S. Fyodorov Eye Microsurgery Federal State Institution, Irkutsk, Russia;

² Irkutsk State Medical University, Irkutsk, Russia;

³ Russian Medical Academy of Continuous Professional Education, Irkutsk, Russia;

⁴ LLC Transneft Technology, Irkutsk, Russia

ABSTRACT

BACKGROUND: A thorough analysis of both optical and anatomical properties of the cornea in patients after anterior radial keratotomy is important in choosing the optical power of an intraocular lens in the surgical treatment of cataracts and other types of optical correction. Improving the classification of postkeratotomic corneal deformity is crucial in modern ophthalmology due to its diverse clinical presentation.

AIM: To develop an automated classification system for postkeratotomic corneal deformity using machine learning and artificial neural networks based on the analysis of topographic maps of the cornea.

MATERIALS AND METHODS: Depersonalized data from medical records of 250 patients aged 46–76 (mean, 59.63±5.95) years were analyzed. Moreover, 500 topographic maps of the anterior and posterior surfaces of the cornea were analyzed, and three stages of machine learning for postkeratotomic corneal deformity classification were performed.

RESULTS: Stage I, which involved topography analysis of the anterior and posterior surfaces of the cornea, allowed for the measurement of anterior and posterior corneal elevation in three ring-shaped zones. At stage II, a direct distribution neural network was selected and created during deep machine learning. Eight auxiliary parameters describing the shape of the anterior and posterior surfaces of the cornea were established. In Stage III, classification algorithms for postkeratotomic corneal deformity were developed based on the test-to-training sample ratio, which ranged from 75% to 91%.

CONCLUSION: The proposed artificial neural network classifies of postkeratotomic corneal deformity types with an accuracy of 91%. The potential for further improving the training quality of this artificial neural network has been established. Neural network algorithms can become a useful tool for the automatic classification of postkeratotomic corneal deformity in patients after radial keratotomy.

Keywords: anterior radial keratotomy; artificial intelligence; machine learning; corneal topography.

To cite this article:

Tsyrenzhapova EK, Rozanova OI, Iureva TN, Ivanov AA, Rozanov IS. Machine-learning and artificial neural network technologies in the classification of postkeratotomic corneal deformity. *Digital Diagnostics*. 2024;5(1):64–74. DOI: <https://doi.org/10.17816/DD624022>

Submitted: 29.11.2023

Accepted: 14.02.2024

Published online: 11.03.2024

DOI: <https://doi.org/10.17816/DD624022>

机器学习和人工神经网络技术在角膜切开术后畸形分类中的应用

Ekaterina K. Tsyrenzhapova¹, Olga I. Rozanova¹, Tatiana N. Iureva^{1, 2, 3}, Andrey A. Ivanov¹, Ivan S. Rozanov⁴

¹ The S. Fyodorov Eye Microsurgery Federal State Institution, Irkutsk, Russia;

² Irkutsk State Medical University, Irkutsk, Russia;

³ Russian Medical Academy of Continuous Professional Education, Irkutsk, Russia;

⁴ LLC Transneft Technology, Irkutsk, Russia

摘要

论证。对前放射状角膜切开术后患者角膜的光学和解剖特性进行仔细分析。这对于选择用于白内障手术和其他类型光学矫正的眼内镜片的光学倍率具有特殊意义。角膜切开术后畸形临床表现的多变性决定了有必要对其进行分类，这也是现代眼科学的一项重要任务。

目的。本研究旨在利用机器学习和人工神经网络开发角膜切开术后角膜畸形自动分类系统。该分类系统的开发基于对角膜图形数值的分析。

材料与方法。以250名患者的匿名病历分析结果为材料。患者年龄在46至76岁之间（平均年龄为59.63±5.95岁）。对500张角膜前后表面的图形，对角膜切开术后畸形分类进行了3个阶段的机器学习。

结果。第一阶段是分析角膜前后表面的图形。通过分析记录了角膜前后表面在三个环形区域的隆起数值。在第二阶段，通过深度机器学习选择并建立了一个前馈神经网络，确定了八个辅助参数。这些参数描述了角膜前后表面的形态。在第三阶段根据测试样本和训练样本的比例，获得了角膜切开术后角膜畸形的分类算法，该比例为75%至91%。

结论。开发了一个人工神经网络。成功解决了角膜切开术后角膜畸形类型的分类问题，准确率高达91%。该神经网络的训练质量还有进一步提高的潜力。人工神经网络算法的应用可以成为对曾接受过放射状角膜切开术的患者进行角膜切开术后角膜畸形自动分类的有用工具。

关键词：前放射状角膜切开术；人工智能；机器学习；角膜图形。

引用本文：

Tsyrenzhapova EK, Rozanova OI, Iureva TN, Ivanov AA, Rozanov IS. 机器学习和人工神经网络技术在角膜切开术后畸形分类中的应用. *Digital Diagnostics*. 2024;5(1):64–74. DOI: <https://doi.org/10.17816/DD624022>

收到: 29.11.2023

接受: 14.02.2024

发布日期: 11.03.2024

ОБОСНОВАНИЕ

Расширение спектра офтальмологических исследований в диагностике глазных заболеваний значительно увеличивает нагрузку на здравоохранение, в частности — на офтальмологические клиники. В то же время такие технологии, как глубокое машинное обучение и искусственные нейронные сети (ИНС), позволяют автоматизировать процесс анализа полученных результатов, увеличивая точность и скорость обнаружения патологии и облегчая процесс принятия решений в деятельности врача. В диагностике глазных заболеваний наиболее ярко представлены модели машинного обучения при оценке изображений глазного дна, помутнений хрусталика, изменения зрительного нерва при глаукоме, данных тонометрии. Кроме того, машинное обучение и искусственный интеллект широко применяется в качестве метода диагностики изменений роговицы. В исследованиях патологии роговицы большое внимание уделяется диагностике кератоконуса [1–6]. Особенно хорошо справляются с задачами распознавания образов и классификации изображений свёрточные нейронные сети (convolutional neural networks), что делает эти алгоритмы разумным выбором для автоматического анализа изображений Шаймпфлюг-камеры с цветовой кодировкой [7]. V.A. Dos Santos и соавт. разработали и обучили нейронную сеть CorneaNet (Австрия) для сегментации изображений, полученных при проведении оптической когерентной томографии роговицы [8]. Тайваньские учёные B.I. Kuo и соавт. ретроспективно оценили результаты топографии роговицы для разработки алгоритма глубокого машинного обучения в диагностике кератоконуса [9]. Работа C. Shi и соавт. показала превосходную эффективность при дифференциальной диагностике субклинического кератоконуса и нормальной роговицы с использованием машинного обучения в сочетании с изображениями Шаймпфлюг-камеры и оптической когерентной томографии сверхвысокого разрешения [10]. В ряде недавних исследований была показана эффективность методов применения свёрточных нейронных сетей для автоматического определения дистрофии Фукса в алгоритме классификации снимков эндотелия роговицы [11].

Вместе с тем в настоящее время отмечается неуклонный прирост пациентов с возрастной катарактой и близорукостью, по поводу которой ранее была выполнена передняя радиальная кератотомия (ПРК). Следует отметить, что ПРК стала первой массово проводимой рефракционной операцией и решила в своё время важную проблему коррекции близорукости у большого числа пациентов в мире. Известно, что рефракционный эффект ПРК основан на изменении оптической силы роговицы вследствие изменения конфигурации её центральной области, что происходит из-за локального ослабления биомеханических свойств роговицы в местах нанесения радиальных дозированных надрезов под действием сил внутриглазного давления. На этапе

разработки ПРК предполагалось, что она приведёт к равномерному уплощению обеих поверхностей роговицы, сохраняя соотношение радиусов кривизны их окружностей. Однако на характер деформации роговицы оказывают влияние исходные параметры глаза (биомеханические свойства роговицы, степень миопии, уровень внутриглазного давления), хирургические факторы (количество, глубина и длина разрезов, качество выполнения операции), а также индивидуальные особенности регенеративных процессов и рубцевания, возраст пациента на момент хирургического вмешательства, образ жизни пациента, процессы старения и т.д. Именно поэтому в отдалённом периоде после ПРК роговица имеет значительные деформационные изменения, что на момент планирования хирургии катаракты с имплантацией интраокулярной линзы приобретает особое значение.

Погрешности в анализе оптических свойств роговицы на дооперационном этапе у пациентов с ранее хирургически модифицированной роговицей могут иметь фатальные последствия в виде рефракционных ошибок и недостаточного качества зрения после операции по поводу катаракты. Именно поэтому тщательный анализ корнеального рельефа у пациентов после ПРК, разработка классификационных критериев посткератотомической деформации роговицы (ПКДР) и создание автоматизированной системы её классификации может стать основой для персонализированного подхода к хирургии катаракты и повышения точности расчёта оптической силы интраокулярной линзы у данной категории пациентов.

ЦЕЛЬ

Разработать автоматизированную систему классификации ПКДР с использованием машинного обучения и ИНС на основе анализа численных значений топографических карт роговицы.

МАТЕРИАЛЫ И МЕТОДЫ

В качестве материала для анализа использовались обезличенные результаты медицинской документации 250 пациентов в возрасте от 46 до 76 лет (средний возраст — $59,63 \pm 5,95$ года), обратившихся в Иркутский филиал Федерального государственного автономного учреждения «Национальный медицинский исследовательский центр «Межотраслевой научно-технический комплекс «Микрохирургия глаза» имени академика С.Н. Фёдорова» Министерства здравоохранения Российской Федерации в период 2020–2023 гг. Всем пациентам помимо стандартного офтальмологического обследования была проведена рельеф-кератотопография на аппарате Pentacam HR (Oculus, Германия). В качестве характеристик оптических свойств роговицы были зафиксированы 38 параметров элевации передней и задней корнеальных поверхностей и 12 параметров, отражающих толщину




Рис. 1. Контрольные точки поверхности роговицы: а — центр роговицы; б — парацентральная зона; с — периферическая зона, диаметром 6 мм.

роговицы, силу преломления, значения астигматизма, асферичности. Исследование проводилось в 3 этапа.

I этап — анализ рельеф-топографии передней и задней поверхностей роговицы

В набор данных были включены по 19 численных значений элевации как передней, так и задней поверхности роговицы из 500 рельеф-топографических карт (дисплей Pentacam 4 maps refractive). Были зафиксированы данные элевации в трёх кольцевидных зонах: в центре, в 4 точках парацентральной зоны и в 14 точках периферической зоны, расположенных на линии окружности диаметром 6 мм. Исследование проводилось начиная с точки, расположенной на 90 градусах, и далее, двигаясь по часовой стрелке. Схематичное расположение топографических точек на элевационной карте роговицы представлено на рис. 1.

II этап — архитектура глубокого обучения и визуализация

Процессы обучения и тестирования разработанной архитектуры выполнялись на персональном компьютере со следующим программным и аппаратным

обеспечением: операционная система Windows 10, процессор AMD Ryzen™ 7 2700E, 16GB RAM. Следует отметить, что графический процессор не использовался для обучения моделей, все необходимые для этого вычисления производились на центральном процессоре. Для программирования использовался язык Python 3.10 с дистрибутивом Anaconda, в частности библиотека tf.keras 2.12.0. Использована реализация спецификации Keras API в рамках фреймворка TensorFlow версии 2.0.

Набор данных включал в себя ключевой параметр «тип», описывающий элевацию передней и задней поверхностей роговицы пациента. На основании рельеф-топографии был определён тип ПКДР. В зависимости от элевационного паттерна передней и задней корнеальных поверхностей всего было выделено 6 типов (табл. 1) [14].

На данной стадии работы была проведена оптимизация набора данных — исследована природа всех параметров с помощью корреляционного и регрессионного анализа, по результатам которых были исключены малоинформативные признаки (рис. 2). Параметр «тип» использовался исключительно для проверки обучения нейросети и не использовался как входной параметр.
















Рис. 2. Процесс обработки набора данных.

Таблица 1. Классификационные типы посткератотомической деформации роговицы в зависимости от элевационного паттерна передней и задней корнеальных поверхностей

Тип деформации	Паттерн элевации передней поверхности роговицы	Паттерн элевации задней поверхности роговицы
1	Незамкнутое кольцо* 	Незамкнутое кольцо* 
2	Замкнутое кольцо* 	Незамкнутое кольцо* 
3	Замкнутое кольцо* 	Замкнутое кольцо* 
4	Незамкнутое кольцо* 	Замкнутое кольцо* 
5	Иррегулярный 	Иррегулярны 
6	Незамкнутое кольцо либо замкнутое кольцо* 	Иррегулярный, присутствует существенное смещение задней поверхности по высоте (свыше 80 мкм) 

* элевация не превышает 80 мкм




Рис. 3. Схематичное представление искусственной нейронной сети последней итерации.

III этап — создание искусственной нейросети

ИНС содержит три слоя: входной, скрытый и выходной — такого количества вполне достаточно для нейросети, выполняющей задачи классификации. Количество нейронов входного слоя $M=12$ (параметры), количество выходного — 6 (классы). Количество нейронов в скрытом слое рассчитано по формуле $M = \frac{2}{3} \times N + K$, где N — количество входных нейронов, а K — количество выходных.

Задачей данного исследования было создать ИНС, работающую с входной таблицей признаков. Схематичное представление ИНС — на рис. 3.

РЕЗУЛЬТАТЫ

В ходе разработки нейросети был создан простой консольный интерфейс с автопроверкой обучения с помощью тестовой выборки (рис. 4). С помощью данного

интерфейса проводилась настройка и подбор оптимального количества эпох обучения. В дальнейшем же, после создания необходимых модулей, громоздкий интерфейс уступил более минималистичному выводу в консоль. Данная процедура позволяет ускорить обучение, снизить сложность и улучшить точность модели.

Для того, чтобы более объективно воспринимать эффективность обучения нейросети, имеет смысл обучать модель партиями и сравнивать средние показатели на каждом цикле обучения (каждой эпохе). Графики зависимости средних показателей обученности нейронных сетей до и после оптимизации набора данных и исключения малозначимых параметров после проведения корреляционного и регрессионного анализа изображены на рис. 5. Установлено, что процесс обучения существенно ускорился после очищения набора данных от однородных переменных и анализа регрессионных оценок. Без этапа подготовки тот же процесс занимал намного больше времени, однако высокой точности и стабильности обучения достичь не удалось и в финальной версии алгоритма.

Полученные нейросети-прототипы не всегда могли определить вид деформации, хотя в процессе постепенно обучались более эффективно выполнять задачу классификации (рис. 6).

Кроме того, можно заметить частое появление ошибки в 4-м и 5-м типах ПКДР (см. рис. 6). Учитывая, что данные классы являются самыми редкими в используемом наборе данных, это может быть проявлением проблемы дисбаланса классов. Несмотря на то, что к 200-й эпохе обучения разница между классами и ошибками их определения практически исчезает, часто в процессе самого обучения ошибки выявляются именно в 4-м и 5-м типе. Это может быть обусловлено тем, что каждая новая ИНС

```
Epoch 177/200
31/31 [=====] - 0s 1ms/step - loss: 0.1250 - accuracy: 0.9542
Epoch 200/200
31/31 [=====] - 0s 1ms/step - loss: 0.1844 - accuracy: 0.9477
+++test+++
1/1 [=====] - 0s 126ms/step - loss: 0.5918 - accuracy: 0.9167
1/1 [=====+=====] - 0s 46ms/step
++++predict n++
[[0.      0.8538249  0.14576246  0.      0.00000004  0.00041263
  0.      ]]
1
++++predict all++
1/1 [=====] - 0s 18ms/step
[112233425566]<--- ответ модели
[112233445566]<--- правильный ответ
Количество верных ответов: 11 / 12
```

Рис. 4. Интерфейс консольного приложения работы с нейросетью (красным отмечен не только неправильный ответ нейросети, но и его коррекция).




Рис. 5. График зависимости обученности от эпохи: *a* — до оптимизации; *b* — после оптимизации.

```

1/1 [=====] - 0s 49ms/step
[122333420126]<--- ответ модели
[112233445566]<--- правильный ответ
Количество верных ответов: 6 / 12
1/1 [=====] - 0s 20ms/step - loss: 2.6415 - accuracy: 0.5000
Модель sequential_82 Эпох обучения: 160
1/1 [=====] - 0s 46ms/step
[212333421126]<--- ответ модели
[112233445566]<--- правильный ответ
Количество верных ответов: 6 / 12
1/1 [=====] - 0s 21ms/step - loss: 6.7181 - accuracy: 0.5833
Модель sequential_83 Эпох обучения: 170
1/1 [=====] - 0s 48ms/step
[112233321136]<--- ответ модели
[112233445566]<--- правильный ответ
Количество верных ответов: 7 / 12
1/1 [=====] - 0s 21ms/step - loss: 3.3654 - accuracy: 0.8333
Модель sequential_84 Эпох обучения: 180
1/1 [=====] - 0s 47ms/step
[112233441516]<--- ответ модели
[112233445566]<--- правильный ответ
Количество верных ответов: 10 / 12

```

Рис. 6. Постепенное обучение нейросети и последующая проверка модели на контрольных точках.

обучается из случайного начального состояния нейронов, однако общая тенденция того, что зачастую большинство ошибок распределено между 4-м и 5-м типом, сохраняется (рис. 7).

В среднем к 200-й эпохе обучения ИНС финальной итерации показывала 91% (11 из 12) верных ответов. Однако размер тестовой выборки был не так велик, а при увеличении тестовой выборки отмечалось уменьшение обучающей части, особенно сильно страдали 4-й и 5-й типы, что связано с малым числом данных. Сокращение выборки на 2 записи из каждого данного класса приводит к уменьшению среднего показателя интеграции к 200-й эпохе до 75%.

ОБСУЖДЕНИЕ

Представленное исследование подчёркивает потенциал применения ИНС для диагностической классификации хирургически модифицированного профиля роговицы после ПРК. Полученные данные после 200 эпох обучения свидетельствуют о достаточно удовлетворительных результатах в пределах 75–91% при различных соотношениях тестовой и обучающей выборок. Вместе с тем возможности ошибок классификации 4-го и 5-го типов требуют увеличения набора данных. Точность классификации в какой-то мере коррелирует с точностью расчётов при построении ИНС, представленными ранее.




Рис. 7. Соотношение ошибок по определению типов посткератотомической деформации роговицы.

Так, М.С. Arbelaez и соавт. (2012) исследовали эффективность метода опорных векторов в классификации кератотопографических данных у пациентов с кератоконусом. В их исследовании были достигнуты высокие показатели чувствительности и специфичности на уровне 92,0% и 97,7% соответственно. Было подчеркнуто, что включение данных о толщине роговицы и её передней и задней поверхностях существенно улучшит выявление субклинического кератоконуса по сравнению с анализом только передней поверхности [15]. Можно также отметить исследование R. Hidalgo и соавт. (2016), где мультипараметрический анализ данных кератотопографических карт с использованием метода опорных векторов продемонстрировал более высокую точность (выше значения площади под ROC-кривой) по сравнению с монопараметрическим анализом (0,922 против 0,809). Средняя чувствительность и специфичность в общей классификации составили 89,0% и 95,2%, а показатель площади под ROC-кривой был равен 0,922 [16].

Результаты работы показывают, что при должной настройке процесса обучения, подготовке входных данных, использовании более объёмной обучающей выборки и выборе оптимальной архитектуры можно добиться весьма высоких и стабильных показателей решения задачи классификации ПКДР. Помимо этого, важно исключить проблемы дисбаланса классов, что может положительно сказаться на качестве обучения ИНС. Хотя использованный метод оценки ошибки перекрёстной энтропии существенно уменьшает данную проблему, нельзя исключить того факта, что 4-й и 5-й типы, как самые малочисленные, страдают сильнее всего и содержат больше всего ошибок.

Перспективным выглядит исследование существующих классов внутри набора данных с независимой кластеризацией записей. Это позволит исключить элемент субъективности первичного деления.

Следует также отметить, что в данном исследовании представлены результаты построения ИНС, работающей с входной таблицей признаков. Однако полученные данные являются основой для последующего построения ИНС, работающей непосредственно с изображениями рельеф-топографических карт роговицы.

ЗАКЛЮЧЕНИЕ

На основе анализа численных значений топографических карт роговицы разработана ИНС, успешно решающая задачу классификации типов ПКДР с точностью 91%. Установлен потенциал для дальнейшего улучшения качества обучения данной ИНС. Применение алгоритмов искусственного интеллекта может стать полезным инструментом автоматической классификации пациентов с ПКДР, обеспечив тем самым своевременную, качественную диагностику и определение дальнейшей тактики ведения пациентов.

ДОПОЛНИТЕЛЬНАЯ ИНФОРМАЦИЯ

Источник финансирования. Авторы заявляют об отсутствии внешнего финансирования при проведении исследования.

Конфликт интересов. Авторы декларируют отсутствие явных и потенциальных конфликтов интересов, связанных с публикацией настоящей статьи.

Вклад авторов. Все авторы подтверждают соответствие своего авторства международным критериям ICMJE (все авторы внесли существенный вклад в разработку концепции, проведение исследования и подготовку статьи, прочли и одобрили финальную версию перед публикацией).

Наибольший вклад распределён следующим образом: О.И. Розанова — разработка концепции и дизайна исследования, написание текста статьи и редактирование, разработка методологии,

руководство исследованием; Е.К. Цыренжапова — проведение исследования, написание текста статьи и редактирование, обзор литературы, подготовка и сбор данных, подготовка черновика статьи, проведение исследования, финальная подготовка статьи к публикации, статистическая обработка данных и их интерпретация; И.С. Розанов — компьютерное сопровождение исследования; Т.Н. Юрева — проведение исследования, финальная подготовка статьи к публикации, статистическая обработка данных и их интерпретация; А.А. Иванов — проведение исследования, обзор литературы, подготовка и сбор данных, подготовка черновика статьи.

ADDITIONAL INFORMATION

Funding source. This study was not supported by any external sources of funding.

Competing interests. The authors declare that they have no competing interests.

Authors' contribution. All authors made a substantial contribution to the conception of the work, acquisition, analysis, interpretation of data for the work, drafting and revising the work, final approval of the version to be published and agree to be accountable for all aspects of the work. O.I. Rozanova — development of the concept and design of the study, writing the text of the article and editing, development of methodology, head of the study; E.K. Tsyrenzhapova — conducting research, writing the text of the article and editing, literature review, preparation and collection of data, preparation of the draft of the article, conducting research, final preparation of the article for publication, statistical data processing and their interpretation; I.S. Rozanov — computer accompaniment of the study; T.N. Iurieva — conducting research, final preparation of the article for publication, statistical data processing and interpretation; A.A. Ivanov — conducting research, literature review, preparation and collection of data, preparation of a draft article.

СПИСОК ЛИТЕРАТУРЫ

1. Issarti I., Consejo A., Jiménez-García M., et al. Computer aided diagnosis for suspect keratoconus detection // *Comput Biol Med.* 2019. Vol. 109. P. 33–42. doi: 10.1016/j.combiomed.2019.04.024
2. Chen X., Zhao J., Iselin K.C., et al. Keratoconus detection of changes using deep learning of colour-coded maps // *BMJ Open Ophthalmol.* 2021. Vol. 6, N 1. P. e000824. doi: 10.1136/bmjophth-2021-000824
3. Feng R., Xu Z., Zheng X., et al. KerNet: A novel deep learning approach for keratoconus and sub-clinical keratoconus detection based on raw data of the pentacam HR system // *IEEE J Biomed Health Inform.* 2021. Vol. 25, N 10. P. 3898–3910. doi: 10.1109/JBHI.2021.3079430
4. Gatinel D. Screening for subclinical keratoconus and prevention of corneal ectasia with SCORE analyzer software. In: Febraro J.-L., Khan H.N., Koch D.D., editors. *Surgical correction of astigmatism.* Cham: Springer International Publishing, 2018. doi: 10.1007/978-3-319-56565-1_9
5. Ruiz Hidalgo I., Rozema J.J., Saad A., et al. Validation of an objective keratoconus detection system implemented in a scheimpflug tomographer and comparison with other methods // *Cornea.* 2017. Vol. 36, N 6. P. 689–695. doi: 10.1097/ICO.0000000000001194
6. Малюгин Б.Э., Сахнов С.Н., Аксенова Л.Е., Мясникова В.В. Применение искусственного интеллекта в диагностике и хирургии кератоконуса: систематический обзор // *Офтальмохирургия.* 2022. № 1. С. 77–96. EDN: PPQRWZ doi: 10.25276/0235-4160-2022-1-77-96
7. Abdelmotaal H., Mostafa M.M., Mostafa A.N.R., et al. Classification of Color-Coded Scheimpflug Camera Corneal Tomography Images Using Deep Learning // *Transl Vis Sci Technol.* 2020. Vol. 9, N 13. P. 30. doi: 10.1167/tvst.9.13.30
8. Dos Santos V.A., Schmetterer L., Stegmann H., et al. CorneaNet: fast segmentation of cornea OCT scans of healthy and keratoconic eyes using deep learning // *Biomed Opt Express.* 2019. Vol. 10, N 2. P. 622–641. doi:10.1364/BOE.10.000622
9. Kuo B.I., Chang W.Y., Liao T.S., et al. Keratoconus Screening Based on Deep Learning Approach of Corneal Topography // *Transl Vis Sci Technol.* 2020. Vol. 9, N 2. P. 53. doi: 10.1167/tvst.9.2.53
10. Shi C., Wang M., Zhu T., et al. Machine learning helps improve diagnostic ability of subclinical keratoconus using Scheimpflug and OCT imaging modalities // *Eye Vis (Lond).* 2020. Vol. 7. P. 48. doi: 10.1186/s40662-020-00213-3
11. Шухаев С.В., Мордовцева Е.А., Пустозеров Е.А., Кудлахмедов Ш.Ш. Применение сверточных нейронных сетей для определения эндотелиальной дистрофии Фукса // *Офтальмохирургия.* 2022. № S4. С. 70–76. EDN: WEZTKV doi: 10.25276/0235-4160-2022-4S-70-76
12. Obaid H.S., Dheyab S.A., Sabry S.S. The impact of data pre-processing techniques and dimensionality reduction on the accuracy of machine learning // *2019 9th Annu. Inf. Technol. Electromechanical Eng. Microelectron. Conf. IEMECON.* 2019. P. 279–283. doi: 10.1109/IEMECONX.2019.8877011
13. Valdés-Mas M.A., Martín-Guerrero J.D., Rupérez M.J., et al. A new approach based on Machine Learning for predicting corneal curvature (K1) and astigmatism in patients with keratoconus after intracorneal ring implantation // *Comput Methods Programs Biomed.* 2014. Vol. 116. P. 39–47. doi: 10.1016/j.cmpb.2014.04.003
14. Патент РФ на изобретение № RU 2793142 C1/ 29.03.2023. Розанова О.И., Цыренжапова Е.К., Юрева Т.Н., и др. Способ оценки рельефа передней и задней поверхности роговицы.
15. Arbelaez M.C., Versaci F., Vestri G., et al. Use of a Support Vector Machine for Keratoconus and Subclinical Keratoconus Detection by Topographic and Tomographic Data // *Ophthalmology.* 2012. Vol. 119, N 11. P. 2231–2238. doi: 10.1016/j.opthta.2012.06.005
16. Ruiz Hidalgo I., Rodriguez P., Rozema J.J., et al. Evaluation of a Machine-Learning Classifier for Keratoconus Detection Based on Scheimpflug Tomography // *Cornea.* 2016. Vol. 35, N 6. P. 827–832. doi: 10.1097/ico.0000000000000834

REFERENCES

1. Issarti I, Consejo A, Jiménez-García M, et al. Computer aided diagnosis for suspect keratoconus detection. *Comput Biol Med.* 2019;109:33–42. doi: 10.1016/j.compbiomed.2019.04.024
2. Chen X, Zhao J, Iselin KC, et al. Keratoconus detection of changes using deep learning of colour-coded maps. *BMJ Open Ophthalmol.* 2021;6(1):e000824. doi: 10.1136/bmjophth-2021-000824
3. Feng R, Xu Z, Zheng X, et al. KerNet: A novel deep learning approach for keratoconus and sub-clinical keratoconus detection based on raw data of the pentacam HR system. *IEEE J Biomed Health Inform.* 2021;25(10):3898–3910. doi: 10.1109/JBHI.2021.3079430
4. Gatinel D. Screening for subclinical keratoconus and prevention of corneal ectasia with SCORE analyzer software. In: Febraro J-L, Khan HN, Koch DD, editors. *Surgical correction of astigmatism*. Cham: Springer International Publishing; 2018. doi: 10.1007/978-3-319-56565-1_9
5. Ruiz Hidalgo I, Rozema JJ, Saad A, et al. Validation of an objective keratoconus detection system implemented in a scheimpflug tomographer and comparison with other methods. *Cornea.* 2017;36(6):689–695. doi: 10.1097/ICO.0000000000001194
6. Malyugin BE, Sakhnov SN, Axenova LE, Myasnikova VV. Application of artificial intelligence in diagnostics and surgery of keratoconus: a systematic overview. *Fyodorov Journal of Ophthalmic Surgery.* 2022;(1):77–96. EDN: PPQRWZ doi: 10.25276/0235-4160-2022-1-77-96
7. Abdelmotaal H, Mostafa MM, Mostafa ANR, et al. Classification of Color-Coded Scheimpflug Camera Corneal Tomography Images Using Deep Learning. *Transl Vis Sci Technol.* 2020;9(13):30. doi: 10.1167/tvst.9.13.30
8. Dos Santos VA, Schmetterer L, Stegmann H, et al. CorneaNet: fast segmentation of cornea OCT scans of healthy and keratoconic eyes using deep learning. *Biomed Opt Express.* 2019;10(2):622–641. doi:10.1364/BOE.10.000622
9. Kuo BI, Chang WY, Liao TS, et al. Keratoconus Screening Based on Deep Learning Approach of Corneal Topography. *Transl Vis Sci Technol.* 2020;9(2):53. doi:10.1167/tvst.9.2.53
10. Shi C, Wang M, Zhu T, et al. Machine learning helps improve diagnostic ability of subclinical keratoconus using Scheimpflug and OCT imaging modalities. *Eye Vis (Lond).* 2020;7:48. doi: 10.1186/s40662-020-00213-3
11. Shukhaev SV, Mordovtseva EA, Pustozarov EA, Kudlakhmedov SS. Application of convolutional neural networks to define Fuchs endothelial dystrophy. *Fyodorov Journal of Ophthalmic Surgery.* 2022;(S4):70–76. EDN: WEZTKV doi: 10.25276/0235-4160-2022-4S-70-76
12. Obaid HS, Dheyab SA, Sabry SS. The impact of data pre-processing techniques and dimensionality reduction on the accuracy of machine learning. *2019 9th Annu. Inf. Technol. Electromechanical Eng. Microelectron. Conf. IEMECON.* 2019:279–283. doi: 10.1109/IEMECONX.2019.8877011
13. Valdés-Mas MA, Martín-Guerrero JD, Rupérez MJ, et al. A new approach based on Machine Learning for predicting corneal curvature (K1) and astigmatism in patients with keratoconus after intracorneal ring implantation. *Comput Methods Programs Biomed.* 2014;116:39–47. doi: 10.1016/j.cmpb.2014.04.003
14. Patent RUS № RU 2793142 C1/ 29.03.2023. Rozanova OI, Tsyrenzhapova EK, Iureva TN, et al. A method of evaluating the relief of the anterior and posterior corneal surface. (In Russ).
15. Arbelaez MC, Versaci F, Vestri G, et al. Use of a Support Vector Machine for Keratoconus and Subclinical Keratoconus Detection by Topographic and Tomographic Data. *Ophthalmology.* 2012;119(11):2231–2238. doi: 10.1016/j.ophtha.2012.06.005
16. Ruiz Hidalgo I, Rodriguez P, Rozema JJ, et al. Evaluation of a Machine-Learning Classifier for Keratoconus Detection Based on Scheimpflug Tomography. *Cornea.* 2016;35(6):827–832. doi: 10.1097/ico.0000000000000834

ОБ АВТОРАХ

* Цыренжапова Екатерина Кирилловна;

адрес: Россия, 664033, г. Иркутск, ул. Лермонтова, 337;
ORCID: 0000-0002-6804-8268;
eLibrary SPIN: 1158-5233;
e-mail: katyakel@mail.ru

Розанова Ольга Ивановна, д-р мед. наук;

ORCID: 0000-0003-3139-2409;
eLibrary SPIN: 6557-9123;
e-mail: olgrozanova@gmail.com

Юрьева Татьяна Николаевна, д-р мед. наук, профессор;

ORCID: 0000-0003-0547-7521;
eLibrary SPIN: 8457-5851;
e-mail: tnyurieva@mail.ru

Иванов Андрей Александрович;

ORCID: 0009-0001-4235-9252;
e-mail: ivanov.andrei.med@yandex.ru

Розанов Иван Сергеевич;

ORCID: 0009-0001-7202-0428;
e-mail: nauka@mntk.irkutsk.ru

AUTHORS' INFO

* Ekaterina K. Tsyrenzhapova, MD;

address: 337 Lermontov street, 664033, Irkutsk, Russia;
ORCID: 0000-0002-6804-8268;
eLibrary SPIN: 1158-5233;
e-mail: katyakel@mail.ru

Olga I. Rozanova, MD, Dr. Sci. (Medicine);

ORCID: 0000-0003-3139-2409;
eLibrary SPIN: 6557-9123;
e-mail: olgrozanova@gmail.com

Tatiana N. Iureva, MD, Dr. Sci. (Medicine), Professor;

ORCID: 0000-0003-0547-7521;
eLibrary SPIN: 8457-5851;
e-mail: tnyurieva@mail.ru

Andrey A. Ivanov, MD;

ORCID: 0009-0001-4235-9252;
e-mail: ivanov.andrei.med@yandex.ru

Ivan S. Rozanov;

ORCID: 0009-0001-7202-0428;
e-mail: nauka@mntk.irkutsk.ru

* Автор, ответственный за переписку / Corresponding author

DOI: <https://doi.org/10.17816/DD623956>

Организация диспансерного наблюдения пациентов с патологией макулярной области сетчатки с использованием систем искусственного интеллекта

А.Д. Чупров¹, И.П. Болодурина^{2,3}, А.О. Лосицкий¹, А.Ю. Жигалов²¹ Национальный медицинский исследовательский центр «Межотраслевой научно-технический комплекс “Микрохирургия глаза” имени академика С.Н. Федорова», Оренбург, Россия;² Оренбургский государственный университет, Оренбург, Россия;³ Оренбургский государственный медицинский университет, Оренбург, Россия

АННОТАЦИЯ

Обоснование. Несмотря на то, что в приказе Министерства здравоохранения Российской Федерации «Об утверждении порядка оказания медицинской помощи взрослому населению при заболеваниях глаза, его придаточного аппарата и орбиты» сказано про оснащение медицинского консультативно-диагностического отделения поликлиники оптическим когерентным томографом, динамическое наблюдение пациентов с патологией сетчатки после начала лечения осуществляется чаще всего в медицинском офтальмологическом центре, что снижает доступность лечения для пациентов со впервые выявленной (первичной) патологией, требующей как можно более раннего начала лечения. Имеющаяся технология нуждается в изменении и интенсификации, в том числе — с применением технологий искусственного интеллекта.

Цель — разработка методических основ организационной технологии диспансерного наблюдения пациентов с патологией заднего отрезка глаза с использованием систем поддержки принятия врачебных решений на основе искусственного интеллекта.

Материалы и методы. Оценка существующей нормативной базы проведена на основе анализа Конституции Российской Федерации, федеральных законов, подзаконной нормативной базы и судебной практики. Создание структурированного медицинского документа описания снимка оптической когерентной томографии проведено с использованием экспертного метода: анкетирования 100 врачей-офтальмологов, имеющих соответствующий уровень образования, в том числе дополнительное профессиональное, занимающихся оказанием медицинских услуг — специализированной медицинской помощи пациентам с патологией заднего отрезка глаза. Структурированный медицинский документ послужил основой для формирования предикторов искусственных нейронных сетей. Обучение нейронных сетей проведено с использованием 60 000 медицинских изображений с помощью метода классификации и сегментации в зависимости от признака.

Результаты. Экспертным методом отобрано и описано 123 бинарных признака, позволяющих описать структуру макулярной области сетчатки в норме и при патологии, из которых выявлено 26 признаков, которые могут быть интерпретированы в качестве предикторов ухудшения клинического течения заболевания.

Заключение. Разработанный классификатор позволил создать и обучить на основе 60 000 медицинских изображений систему поддержки принятия врачебных решений, которая в качестве информационного сервиса, без постановки диагноза, может позволить изменить организацию процесса динамического наблюдения. Формирование маршрутизации пациентов — первичная услуга разработанной системы поддержки принятия врачебных решений. При наличии признаков ухудшения клинической картины предполагается маршрутизация в медицинский офтальмологический центр для оценки динамики и оказания специализированной, в том числе высокотехнологичной, медицинской помощи.

Ключевые слова: система поддержки принятия врачебных решений; искусственный интеллект; оптическая когерентная томография; патология; макула.

Как цитировать:

Чупров А.Д., Болодурина И.П., Лосицкий А.О., Жигалов А.Ю. Организация диспансерного наблюдения пациентов с патологией макулярной области сетчатки с использованием систем искусственного интеллекта // Digital Diagnostics. 2024. Т. 5, № 1. С. 75–84. DOI: <https://doi.org/10.17816/DD623956>

DOI: <https://doi.org/10.17816/DD623956>

Organizing follow-up care for patients with macular retinal pathologies using artificial intelligence systems

Aleksandr D. Chuprov¹, Irina P. Bolodurina^{2,3}, Aleksandr O. Lositskiy¹, Artur Yu. Zhigalov²

¹ The S. Fyodorov Eye Microsurgery Federal State Institution, Orenburg, Russia;

² Orenburg State University, Orenburg, Russia;

³ Orenburg State Medical University, Orenburg, Russia

ABSTRACT

BACKGROUND: The Order of the Ministry of Health of Russia “On Approval of the Procedure for the Provision of Medical Care to the Adult Population for Diseases of the Eye, Appendages, and Orbit” provides for equipping consultation and diagnostic departments of outpatient clinics with optical coherence tomographs. However, case follow-up in of patients with retinal pathology is most commonly performed in ophthalmology centers, limiting treatment accessibility for patients with primary (newly diagnosed) pathologies requiring immediate treatment initiation. The available approach requires modification and intensification, including the use of artificial intelligence technologies.

AIM: To develop methodological foundations for organizing follow-up care for patients with posterior segment eye diseases using an artificial intelligence-based clinical decision support system.

MATERIALS AND METHODS: The existing regulatory framework was analyzed based on the Constitution of the Russian Federation, federal laws, by-law framework, and judicial practice. A structured medical document describing an optical coherence tomography image was created using an expert method: a survey of 100 ophthalmologists with an appropriate education level, including additional professional training, engaged specialized medical care for patients with posterior segment eye diseases was performed.

RESULTS: Using an expert method, 123 binary features were selected to describe the structure of the macular area of the retina under normal and pathological conditions, with 26 features identified as predictors of a worsening clinical course of the disease.

CONCLUSION: The proposed classifier enabled the creation and training of a medical decision support system based on 60,000 medical images, which, as an information service, without making a diagnosis, can change the case follow-up process. Routing of patients is a primary service of the proposed system. If the clinical picture shows signs of deterioration, a referral to an ophthalmology center is considered to assess the course of the disease and provide specialized services, including high-tech medical care.

Keywords: clinical decision support system; artificial intelligence; optical coherence tomography; pathology; macular.

To cite this article:

Chuprov AD, Bolodurina IP, Lositskiy AO, Zhigalov AY. Organizing follow-up care for patients with macular retinal pathologies using artificial intelligence systems. *Digital Diagnostics*. 2024;5(1):75–84. DOI: <https://doi.org/10.17816/DD623956>

DOI: <https://doi.org/10.17816/DD623956>

利用人工智能系统组织对视网膜黄斑病变患者的防治观察

Aleksandr D. Chuprov¹, Irina P. Bolodurina^{2, 3}, Aleksandr O. Lositskiy¹, Artur Yu. Zhigalov²

¹ The S. Fyodorov Eye Microsurgery Federal State Institution, Orenburg, Russia;

² Orenburg State University, Orenburg, Russia;

³ Orenburg State Medical University, Orenburg, Russia

摘要

论证。根据俄罗斯联邦卫生部命令《关于向成年居民提供眼部、眼部附属装置和眼眶疾病医疗服务的程序批准》，综合医院的医疗咨询和诊断部门都配备光学相干断层扫描仪。然而，视网膜病变患者在开始治疗后的动态观察通常是在专门眼科医疗中心进行。这就降低了对首次发现（原发性）病变患者的治疗机会，因为这些患者需要尽早开始治疗。需要改变和加强现有技术，包括使用人工智能技术。

目的。本研究旨在利用基于人工智能的医疗决策支持系统，为眼后段病变患者的防治观察组织技术奠定方法论基础。

材料和方法。在对《俄罗斯联邦宪法》、联邦法律、附属法规和司法实践分析的基础上，对现有管理框架进行了评估。使用专家方法编制了描述光学相干断层扫描图像的结构化医学文件：对100名具有适当教育水平的眼科医生进行了问卷调查，包括额外的专业教育。所有医生都从事医疗服务工作，即为眼后段病变患者提供专业医疗服务。结构化医疗文件是形成人工神经网络预测器的基础。利用基于特征的分类和分割方法，使用60000张医学图像对神经网络进行了训练。

结果。通过专家方法选取并描述了123个能够描述正常和病理下视网膜黄斑区结构的二元特征。其中，26个特征被确定为疾病临床过程恶化的预测器。

结论。所开发的分类器可以在60000张医学图像的基础上创建和训练一个医疗决策支持系统。该系统可用作信息服务。它可以在不做出诊断的情况下改变动态观察过程的组织结构。患者路径选择是已开发的医疗决策支持系统的主要服务。如果临床症状有恶化的迹象，患者就会被转诊到眼科医疗中心，以接受动态评估及包括高科技在内的专业医疗服务。

关键词：医疗决策支持系统；人工智能；光学相干断层扫描；病变；黄斑。

引用本文：

Chuprov AD, Bolodurina IP, Lositskiy AO, Zhigalov AYU. 利用人工智能系统组织对视网膜黄斑病变患者的防治观察. *Digital Diagnostics*. 2024;5(1):75–84. DOI: <https://doi.org/10.17816/DD623956>

收到: 28.11.2023

接受: 11.03.2024

发布日期: 15.03.2024

ОБОСНОВАНИЕ

Использование искусственного интеллекта с целью повышения производительности организаций всех форм собственности определено Национальной стратегией развития искусственного интеллекта, принятой в Российской Федерации¹. Это может достигаться за счёт автоматизации рутинных (повторяющихся) производственных процессов и операций.

В соответствии с действующими клиническими рекомендациями, пациентам с патологией сетчатки при сахарном диабете и возрастной макулярной дегенерацией рекомендуются периодические осмотры врачом-офтальмологом при наличии факторов риска прогрессирования заболевания — с целью динамического наблюдения изменений и назначения (при необходимости) адекватного лечения [1, 2]. Исследование сетчатки с помощью компьютерного анализатора — структурная оптическая когерентная томография (ОКТ) — входит в стандарт оказания первичной специализированной медицинской помощи при диабетической ретинопатии и возрастной макулодистрофии и является повторяющейся услугой². Частота визитов к врачу определяется индивидуально в зависимости от планируемой тактики ведения и особенностей клинических проявлений. По данным отечественной литературы, минимальное число исследований макулярной области сетчатки с помощью ОКТ, проводимых в медицинских организациях при динамическом наблюдении пациентов с возрастной макулярной дегенерацией и диабетическим макулярным отёком, составляет 1 629 429 в год.

Зарубежные аналитические отчёты показывают готовность пациентов перейти на контролируемое самолечение при динамическом наблюдении заболевания (до 54% опрошенных лиц по данным за 2019 г., STADA Health Report 2020) и получать часть медицинских услуг с использованием телемедицинских технологий дистанционно, без очной консультации медицинского специалиста [3–5]. Согласно результатам исследования Всероссийского центра изучения общественного мнения, 48% россиян допускают динамическое наблюдение и коррекцию лечения с использованием телемедицинских услуг [6]. Таким образом, имеются организационные и клинические предпосылки для оказания медицинских услуг с использованием искусственного интеллекта, в том числе с применением телемедицинских технологий, у пациентов с повторным диагностическим приёмом в рамках динамического наблюдения патологии заднего отрезка глаза.

Несмотря на то, что в приказе Министерства здравоохранения Российской Федерации от 12 ноября 2012 г. N 902н «Об утверждении порядка оказания медицинской помощи взрослому населению при заболеваниях глаза, его придаточного аппарата и орбиты» говорится об оснащении медицинского консультативно-диагностического отделения поликлиники оптическим когерентным томографом, динамическое наблюдение пациентов с патологией сетчатки после начала лечения осуществляется чаще всего в медицинском офтальмологическом центре, что снижает доступность лечения для пациентов с впервые выявленной патологией, требующей как можно более раннего начала лечения. Имеющаяся технология нуждается в изменении и интенсификации, в том числе — с применением технологий искусственного интеллекта.

ЦЕЛЬ

Разработка методических основ организационной технологии диспансерного наблюдения пациентов с патологией заднего отрезка глаза с использованием систем поддержки принятия врачебных решений (СППВР) на основе искусственного интеллекта.

МАТЕРИАЛЫ И МЕТОДЫ

Для оценки существующей нормативной базы использован контент-анализ. Для создания структурированного справочника были использованы социологический и экспертный методы. Обучение искусственных нейронных сетей (ИНС) произведено методами сегментации и классификации.

Дизайн исследования

Оценка существующей нормативной базы проведена на основе анализа Конституции Российской Федерации, федеральных законов, подзаконной нормативной базы, судебной практики. Создание методологии структурированного медицинского документа описания снимка ОКТ проведено с использованием экспертного метода: анкетирования 100 врачей-офтальмологов, имеющих соответствующий уровень образования, в том числе дополнительное профессиональное, занимающихся оказанием медицинских услуг — специализированной медицинской помощи пациентам с патологией заднего отрезка глаза. Структурированный медицинский документ послужил основой для формирования предикторов ИНС. В результате аннотирования описано 60 000 медицинских изображений. Для каждого

¹ Указ Президента РФ от 10.10.2019 N 490 «О развитии искусственного интеллекта в Российской Федерации» (вместе с «Национальной стратегией развития искусственного интеллекта на период до 2030 года»). Режим доступа: https://www.consultant.ru/document/cons_doc_LAW_335184/1f32224a00901db9cf44793e9a5e35567a4212c7/ Дата обращения: 22.11.2023.

² Приказ Министерства здравоохранения Российской Федерации от 24 декабря 2012г. N 1492н «Об утверждении стандарта первичной медицинской помощи при диабетической ретинопатии и диабетическом макулярном отеке». Режим доступа: <https://base.garant.ru/70344052/53f89421bbdaf741eb2d1ecc4ddb4c33/> Дата обращения: 22.11.2023.

отдельного изображения существует файл в формате json, описывающий наличие на нём признаков после разметки. Для анализа и классификации бинарных признаков на изображении обучены нейронные сети с архитектурой DenseNet121 без предварительно обученных весов. В задаче сегментации использована архитектура Mask R-CNN.

Критерии соответствия

Включение признака в состав значимых, свидетельствующих об ухудшении клинического процесса, проводилось по достижении согласия 70% респондентов. Включение признака в вывод СППВР достигалось при достижении показателем ассигасы (среднее значение чувствительности и специфичности) значения 0,7 и выше.

Условия проведения

База данных составлена на основе обезличенных данных клинических исследований (исследование сетчатки с помощью компьютерного анализатора), проведённых в Оренбургском и Тамбовском филиалах Федерального государственного автономного учреждения «Национальный медицинский исследовательский центр “Межотраслевой научно-технический комплекс «Микрохирургия глаза» имени академика С.Н. Федорова”» Министерства здравоохранения Российской Федерации. Обучение ИНС осуществлялось на базе Научно-исследовательского института цифровых интеллектуальных технологий Федерального государственного бюджетного образовательного учреждения высшего образования «Оренбургский государственный университет».

Продолжительность исследования

Клинические исследования (исследования сетчатки с помощью компьютерного анализатора) проводились в период с 2015 по 2023 гг., создание структурированного бинарного классификатора-справочника описания макулярной области сетчатки проходило в 2022 г., обучение ИНС проходило в период 2022–2023 гг.

Описание медицинского вмешательства

Для набора базы данных проводилось исследование сетчатки глаза с помощью компьютерного анализатора: ОКТ макулярной области сетчатки глаза.

Основной исход исследования

Разработаны и оценены методические основы использования искусственного интеллекта в организации диспансерного наблюдения за пациентами с патологией заднего отрезка глаза.

Анализ в подгруппах

Методология диспансерного наблюдения сформирована на основании оценки организации медицинской помощи и клинических данных пациентов с диагнозом «возрастная макулярная дегенерация» (шифр кода

в Международной классификации болезней 10-го пересмотра: Н 35.3) или «диабетический макулярный отёк» (шифр Н 35.8).

Методы регистрации исходов

Чувствительность и специфичность — статистические показатели диагностического теста по выявлению больных и здоровых, выводимые из ошибок первого и второго рода в бинарной классификации.

Статистический анализ

Принципы расчёта размера выборки: минимальный объём выборочного исследования определён с учётом критерия достоверности, предельной ошибки (произведение доверительного интервала и заданной точности).

Статистическая обработка материала включала методы описательной статистики: расчёт средних величин, расчёт относительных величин, математическое моделирование. Анализ статистической значимости отличий изучаемых данных по качественным признакам осуществлялся посредством математического расчёта и последующей оценки критерия хи-квадрат Пирсона. Количественные переменные описывались при предварительной их оценке на соответствие закону Гаусса–Лапласа (закон нормального распределения вероятностей).

РЕЗУЛЬТАТЫ

Объекты (участники) исследования

Объектом исследования явилась система организации офтальмологической помощи взрослому населению при диспансерном наблюдении патологии заднего отрезка глаза. В рамках контент-анализа проанализировано 22 нормативно-правовых акта. База данных — медицинская информационная система, включающая 60 000 записей о проведённом исследовании сетчатки глаза с помощью компьютерного анализатора с наличием медицинского изображения (снимка) и описания интерпретации результата исследования в соответствии с разработанным бинарным классификатором.

Основные результаты исследования

В Российской Федерации, согласно Федеральному закону от 21.11.2011 N 323-ФЗ «Об основах охраны здоровья граждан в Российской Федерации», медицинская помощь организуется и оказывается:

- 1) в соответствии с положением об организации оказания медицинской помощи по видам медицинской помощи;
- 2) в соответствии с порядками оказания медицинской помощи, утверждаемыми уполномоченным федеральным органом исполнительной власти и обязательными для исполнения на территории Российской Федерации всеми медицинскими организациями;
- 3) на основе клинических рекомендаций;

4) с учётом стандартов медицинской помощи, утверждаемых уполномоченным федеральным органом исполнительной власти³.

Кроме того, в пункте 15 статьи 2 этого закона даётся определение понятия «лечащий врач». Это врач, на которого возложены функции по организации и непосредственному оказанию пациенту медицинской помощи в период наблюдения за ним и его лечения. Отдельные функции лечащего врача могут быть возложены при оказании первичной специализированной медицинской помощи на средний медицинский персонал в соответствии с утверждённым Порядком, однако там отсутствует возможность возложения оказания первичной специализированной медицинской помощи, в том числе медицинских услуг, входящих в профессиональный стандарт врача-офтальмолога^{4,5}. Интерпретация результатов инструментальных исследований не может быть осуществлена средним медицинским персоналом самостоятельно при предоставлении медицинских услуг. Это возможно только в рамках использования зарегистрированных медицинских изделий.

СППВР требуют регистрации в качестве медицинского изделия для использования средним медицинским персоналом. При использовании же врачами они могут оставаться в правовом поле информационных сервисов, так как интерпретация результатов, постановка диагноза и формирование рекомендаций, в том числе в рамках диспансерного наблюдения, остаются в поле компетенции лечащего врача вне зависимости от правового статуса программы.

Экспертным методом отобрано и описано 123 бинарных признака, позволяющих описать структуру макулярной области сетчатки в норме и при патологии. Признаки объединены по разделам: общий; витреоретинальный и ретинальный интерфейс; контур сетчатки; толщина сетчатки; структуры сетчатки; хориоидея. По итогам анкетирования специалистов, имеющих соответствующее образование и опыт работы, было выявлено, что 75% врачей относят лишь 26 признаков из 123 к предикторам ухудшения клинического течения основного заболевания у пациентов с диагнозом «возрастная макулярная дегенерация» или «диабетический макулярный отёк» (табл. 1).

Полученные характеристики прямо или косвенно свидетельствуют о развитии патологического процесса, в том числе неоваскуляризации, которая требует оказания

специализированной и высокотехнологичной медицинской помощи в медицинских организациях 3-го уровня, в том числе федеральных медицинских организациях. Характеристики также соотносятся с клиническими рекомендациями и современной научной литературой, описывающей оказание медицинской помощи и интерпретацию результатов инструментальных диагностических исследований [7, 8].

Бинарный классификатор разделён на признаки, подходящие для использования при обучении ИНС методом классификации и сегментации. Обучение ИНС, проведённое с использованием 60 000 медицинских изображений, позволило создать СППВР при динамическом наблюдении пациентов с патологией заднего отрезка глаза. Точность моделей ИНС оценивалась с помощью метрики «сбалансированная точность», для корректного учёта неоднородного распределения классов в данных. Средняя сбалансированная точность по признакам составила 81%.

Дополнительные результаты исследования

Разработанная версия СППВР выложена в открытом доступе: <http://retinadeepai.site/>. Система распознаёт объекты для анализа, являющиеся предикторами по каждому из разработанных признаков, позволяет настроить анализ различных карт и режимов, в том числе полученных на различной аппаратуре. Рекомендуемый режим анализа — RetinaMap. Сервис снабжён эргономичным, интуитивно понятным интерфейсом, позволяет выгрузить отчёт для прикрепления в медицинскую документацию. Сервис не является медицинским изделием, а представляет собой информационную услугу; не хранит, не обрабатывает персональные данные пациентов. Сервис не ставит диагноз, не предлагает варианты диагноза. Он описывает структуру сетчатки в норме и при развитии патологии, забирая на себя часть рутинных процессов врача-офтальмолога при динамическом наблюдении пациентов.

Нежелательные явления

Не выявлены.

ОБСУЖДЕНИЕ

В настоящий момент в мире разрабатывается несколько систем для ранней диагностики патологии глазного дна с использованием искусственного интеллекта.

³ Федеральный закон «Об основах охраны здоровья граждан в Российской Федерации» от 21.11.2011 N 323-ФЗ. Режим доступа: https://www.consultant.ru/document/cons_doc_LAW_121895/ Дата обращения: 22.11.2023.

⁴ Приказ Министерства здравоохранения и социального развития РФ от 23 марта 2012 года N 252н «Об утверждении Порядка возложения на фельдшера, акушерку руководителем медицинской организации при организации оказания первичной медико-санитарной помощи и скорой медицинской помощи отдельных функций лечащего врача по непосредственному оказанию медицинской помощи пациенту в период наблюдения за ним и его лечения, в том числе по назначению и применению лекарственных препаратов, включая наркотические лекарственные препараты и психотропные лекарственные препараты». Режим доступа: <https://base.garant.ru/70170588/> Дата обращения: 22.11.2023.

⁵ Приказ Министерства здравоохранения и социального развития РФ от 5 июня 2017 года N 470н «Об утверждении профессионального стандарта "Врач-офтальмолог"». Режим доступа: <https://docs.cntd.ru/document/436744741> Дата обращения: 22.11.2023.

Таблица 1. Признаки ухудшения клинического течения заболевания

Признак	Раздел
Сетчатка в макуле утолщена умеренно (до 500 мкм)	Толщина сетчатки
Сетчатка в макуле утолщена значительно (свыше 500 мкм)	
Определяется фокальный интравитреальный отёк	Структура сетчатки
Определяется диффузный интравитреальный отёк	
Определяется кистозный интравитреальный отёк	
Изменения в виде мелких (до 50 мкм) множественных кист	
Изменения в виде средних (50–150 мкм) множественных кист	
Изменения в виде крупных (свыше 150 мкм) множественных кист	
Сканируется серозная отслойка нейроретина	
Сканируется серозная отслойка нейроретина	
Сканируется серозная отслойка ПЭС	
Отслойка ПЭС куполообразная	
Сканируется плоская волнообразная отслойка ПЭС	
Сканируется плоская отслойка ПЭС	
Сканируется table-образная отслойка ПЭС	
Сканируется геморрагическая отслойка ПЭС	
Сканируется фиброваскулярная отслойка ПЭС	
Определяется симптом двойного слоя	
Помутнение высокой рефлексивности, дающее «тень» на глубже лежащие слои (субретинальный гемо)	
Сканируется субретинальная жидкость	
Сканируется гиперрефлексивный очаг во внутренних слоях сетчатки	
Сканируется гиперрефлексивный очаг в наружных слоях сетчатки	
Сканируется гиперрефлексивный очаг над ПЭС	
Сканируется гиперрефлексивный очаг в слое ПЭС	
Сканируется гиперрефлексивный очаг под ПЭС	
Сканируется гиперрефлексивный очаг, дающий «тень» на подлежащие слои	

Примечание. ПЭС — пигментный эпителий сетчатки.

Например, системы, выявляющие ранние признаки диабетической ретинопатии по снимкам глазного дна, полученным со стационарных и портативных фундус-камер: система IDx-DR (коммерческое название LumineticsCore, США), платформа Retina.AI (ООО «Диджитал Вижн Солюшнс», Россия).

Кроме того, существует ряд разработок, направленных на автоматизированный анализ данных, полученных с медицинских приборов.

- Платформа Retina.AI направлена на анализ снимков ОКТ сетчатки глаза и нахождение одного из заявленных синдромокомплексов: субретинальная жидкость, интравитреальные кисты, отслойка ретинального пигментного эпителия, субретинальный гиперрефлексивный материал, эпиретинальная мембрана, ретинальные друзы, сквозной макулярный разрыв, ламеллярный макулярный разрыв, витрео-макулярная тракция (<https://www.screenretina.com/>).

Таким образом, разработка направлена на диагностику состояний, оценку динамику процесса. Проект не имеет регистрации в качестве медицинского изделия.

- Платформа Altris AI (США) автоматизирует выбор патологических ОКТ-сканирований и обнаружение более 70 патологий и патологических признаков, в том числе таких, как эпиретинальный фиброз, интравитреальная кистозидная жидкость, псевдокисты, диффузный отёк, фиброваскулярная отслойка пигментного эпителия сетчатки, субретинальный гиперрефлексивный материал и др. (<https://www.altris.ai/>). Миссия проекта в диагностике состояний (заболеваний) и в обучении медицинского персонала. Разработка имеет разрешение в стране-изготовителе на применение в качестве медицинского изделия (Управление по санитарному надзору за качеством пищевых продуктов и медикаментов США).

Разрабатываемый нами продукт содержит большее число оцениваемых признаков (123) и направлен не на диагностику, а на изменение организации процесса диагностики и лечения: перенос рутинной работы с врачебного на средний медицинский персонал, сокращение времени исследования и увеличение доступности медицинской услуги.

Имеется необходимость внесения изменений в профессиональный стандарт среднего медицинского персонала, предусматривающий использование информационных сервисов с применением искусственного интеллекта при динамическом наблюдении пациентов. Кроме того, имеется необходимость актуализации нормативной базы по диспансерному наблюдению пациентов с патологией заднего отрезка глаза, в том числе включение данной патологии в приказ Министерства здравоохранения от 15.03.2023 г. N 168н «Об утверждении порядка проведения диспансерного наблюдения за взрослыми».

Резюме основного результата исследования

Разработаны методические основы организационной технологии диспансерного наблюдения пациентов с патологией заднего отрезка глаза, подготовлен структурный классификатор описания сетчатки глаза, разработана СППВР для использования при диспансерном наблюдении пациентов с данной патологией.

Обсуждение основного результата исследования

Приказом Министерства здравоохранения РФ от 7 сентября 2020 г. N 947н «Об утверждении Порядка организации системы документооборота в сфере охраны здоровья в части ведения медицинской документации в форме электронных документов» определён порядок использования медицинских документов в электронном виде. В настоящее время в России разработано, утверждено и используется значительное количество структурированных электронных медицинских документов. В рамках деятельности Федерального государственного бюджетного учреждения «Центральный научно-исследовательский институт организации и информатизации здравоохранения» Министерства здравоохранения Российской Федерации функционирует Центр по разработке структурированных электронных медицинских документов, который обеспечивает выполнение задач Минздрава России по совершенствованию порядка организации документооборота в сфере охраны здоровья путём разработки, актуализации и модернизации руководств по реализации структурированных электронных медицинских документов. Разработанный справочник может стать основой медицинского документа-протокола инструментального исследования сетчатки глаза с помощью компьютерного анализатора.

Накопление структурированной информации поможет усовершенствовать разработанную СППВР. Изменение

нормативной базы поможет ускорить внедрение организационной технологии диспансерного наблюдения пациентов с патологией заднего отрезка глаза с использованием СППВР на основе искусственного интеллекта.

Ограничения исследования

Результаты исследования предназначены для динамического (диспансерного) наблюдения пациентов с патологией заднего отрезка глаза. Результаты не могут быть использованы при первичной диагностике патологии органа зрения, придаточного аппарата и орбиты.

ЗАКЛЮЧЕНИЕ

В правовом поле Российской Федерации отсутствует возможность передачи части врачебных функций при интерпретации результатов медицинских исследований среднему медицинскому персоналу, что требует доработки как профессионального стандарта, так и нормативной базы по профилю болезней органа зрения, придаточного аппарата и орбиты. Отсутствуют единые правила создания структурированного электронного медицинского документа, содержащего результаты интерпретации исследования сетчатки с помощью компьютерного анализатора. Разработанный классификатор позволил создать и обучить (на основе 60 000 медицинских изображений) СППВР, которая в качестве информационного сервиса, без постановки диагноза, может позволить изменить организацию процесса динамического наблюдения. Формирование маршрутизации пациентов — первичная услуга разработанной СППВР. При наличии признаков ухудшения клинической картины предполагается маршрутизация в медицинский офтальмологический центр для оценки динамики и оказания специализированной, в том числе высокотехнологичной, медицинской помощи.

ДОПОЛНИТЕЛЬНАЯ ИНФОРМАЦИЯ

Источник финансирования. Авторы заявляют об отсутствии внешнего финансирования при проведении исследования.

Конфликт интересов. Авторы декларируют отсутствие явных и потенциальных конфликтов интересов, связанных с публикацией настоящей статьи.

Вклад авторов. Все авторы подтверждают соответствие своего авторства международным критериям ICMJE (все авторы внесли существенный вклад в разработку концепции, проведение поисково-аналитической работы и подготовку статьи, прочли и одобрили финальную версию перед публикацией). Наибольший вклад распределён следующим образом: А.Д. Чупров, И.П. Боллодурин — разработка концепции, утверждение итогового варианта рукописи; А.О. Лосицкий — разработка методологии, сбор базы данных, написание и редактирование текста статьи; А.Ю. Жигалов — разработка методологии, проведение исследования.

ADDITIONAL INFO

Funding source. This study was not supported by any external sources of funding.

Competing interests. The authors declare that they have no competing interests.

Authors' contribution. All authors made a substantial contribution to the conception of the work, acquisition, analysis,

interpretation of data for the work, drafting and revising the work, final approval of the version to be published and agree to be accountable for all aspects of the work. A.D. Chuprov, I.P. Bolodurina — development of the concept, approval of the final version of the manuscript; A.O. Lositskiy — development of methodology, database collection, writing and editing the text of the article; A.Yu. Zhigalov — development of methodology, conducting research.

СПИСОК ЛИТЕРАТУРЫ

1. Клинические рекомендации — Сахарный диабет: ретинопатия диабетическая, макулярный отек диабетический. ID 115. Одобрено Научно-практическим Советом Минздрава РФ. 2023. Режим доступа: https://cr.minzdrav.gov.ru/recomend/115_2 Дата обращения: 22.11.2023.
2. Клинические рекомендации — Макулярная дегенерация возрастная. ID 114. Одобрено Научно-практическим Советом Минздрава РФ. 2021. Режим доступа: https://cr.minzdrav.gov.ru/recomend/114_2 Дата обращения: 22.11.2023.
3. Health Tech Digital [Internet]. c2018–2024. Digital Therapeutics and Wellness App Users to Reach 1.4 Billion Globally by 2025, as Pandemic Accelerates Regulatory Acceptance. Доступ по ссылке: <https://www.healthtechdigital.com/digital-therapeutics-and-wellness-app-users-to-reach-1-4-billion-globally-by-2025-as-pandemic-accelerates-regulatory-acceptance/> Дата обращения: 22.11.2023.
4. Пугачев П.С., Гусев А.В., Кобякова О.С., и др. Мировые тренды цифровой трансформации отрасли здравоохранения // Нацио-

- нальное здравоохранение. 2021. Т. 2, № 2. С. 5–12. EDN: JADWXN doi: 10.47093/2713-069X.2021.2.2.5-12
5. STADA Health Report 2020. Режим доступа: https://www.stada.com/media/5774/stada_healthreport2020_en.pdf Дата обращения: 22.11.2023.
 6. Медведева Е.И., Александрова О.А., Крошили С.В. Телемедицина в современных условиях: отношение социума и вектор развития // Экономические и социальные перемены: факты, тенденции, прогноз. 2022. Т. 15, № 3. С. 200–222 doi: 10.15838/esc.2022.3.81.11
 7. Ламброзо Б., Рисполи М. ОКТ сетчатки. Метод анализа и интерпретации / под ред. В.В. Нероева, О.В. Зайцевой. Москва : Апрель, 2012.
 8. Аветисов С.Э., Кац М.В. Использование оптической когерентной томографии в диагностике заболеваний сетчатки (обзор литературы) // Universum: медицина и фармакология. 2017. № 4(38). С. 15–26. EDN: YJAYXT

REFERENCES

1. *Diabetes mellitus: diabetic retinopathy, diabetic macular edema. Clinical guidelines.* ID 115. Approved by the Scientific and Practical Council of the Ministry of Health of the Russian Federation. 2023. Available from: https://cr.minzdrav.gov.ru/recomend/115_2 (In Russ).
2. *Age-related macular degeneration. Clinical guidelines.* ID 114. Approved by the Scientific and Practical Council of the Ministry of Health of the Russian Federation. 2021. Available from: https://cr.minzdrav.gov.ru/recomend/114_2 (In Russ).
3. Health Tech Digital [Internet]. c2018–2024. Digital Therapeutics and Wellness App Users to Reach 1.4 Billion Globally by 2025, as Pandemic Accelerates Regulatory Acceptance. Available from: <https://www.healthtechdigital.com/digital-therapeutics-and-wellness-app-users-to-reach-1-4-billion-globally-by-2025-as-pandemic-accelerates-regulatory-acceptance/> Cited 2023 Nov 22.

4. Pugachev PS, Gusev AV, Kobyakova OS, et al. Global trends in the digital transformation of the healthcare industry. *National Health Care (Russia)*. 2021;2(2):5–12. EDN: JADWXN doi: 10.47093/2713-069X.2021.2.2.5-12
5. STADA Health Report 2020. Available from: https://www.stada.com/media/5774/stada_healthreport2020_en.pdf Cited 2023 Nov 22.
6. Medvedeva EI, Aleksandrova OA, Kroshilin SV. Telemedicine in modern conditions: the attitude of society and the vector of development. *Economic And Social Changes: Facts, Trends, Forecast*, 2022;15(3):200–222. doi: 10.15838/esc.2022.3.81.11
7. Lumbroso B, Rispoli M. *Retinal OCT. Method of analysis and interpretation*. Neroev VV, Zaitseva OV, editors. Moscow: April; 2012. (In Russ).
8. Avetisov S, Kats M. Using optical coherent tomography in diagnosis of retinal diseases. (review of literature). *Universum: meditsina i farmakologiya*. 2017;(4(38)):15–26. EDN: YJAYXT

ОБ АВТОРАХ

* **Лосицкий Александр Олегович**, канд. мед. наук;
адрес: Россия, 460047, Оренбург, улица Салмышская, д. 17;
ORCID: 0000-0002-8716-6438;
eLibrary SPIN: 2044-3410;
e-mail: eyedoct@yandex.ru

AUTHORS' INFO

* **Aleksandr O. Lositskiy**, MD, Cand. Sci. (Medicine);
address: 17 Salmyskaya street, 460047 Orenburg, Russia;
ORCID: 0000-0002-8716-6438;
eLibrary SPIN: 2044-3410;
e-mail: eyedoct@yandex.ru

* Автор, ответственный за переписку / Corresponding author

Чупров Александр Дмитриевич, д-р мед. наук, профессор;
ORCID: 0000-0001-7011-4220;
e-mail: nauka@ofmntk.ru

Болодурина Ирина Павловна, д-р техн. наук, профессор;
ORCID: 0000-0003-0096-2587;
eLibrary SPIN: 4848-0669;
e-mail: prmat@mail.osu.ru

Жигалов Артур Юрьевич;
ORCID: 0000-0003-3208-1629;
eLibrary SPIN: 4692-9037;
e-mail: prmat@mail.osu.ru

Aleksandr D. Chuprov, MD, Dr. Sci. (Medicine), Professor;
ORCID: 0000-0001-7011-4220;
e-mail: nauka@ofmntk.ru

Irina P. Bolodurina, Dr. Sci. (Engineering), Professor;
ORCID: 0000-0003-0096-2587;
eLibrary SPIN: 4848-0669;
e-mail: prmat@mail.osu.ru

Artur Yu. Zhigalov;
ORCID: 0000-0003-3208-1629;
eLibrary SPIN: 4692-9037;
e-mail: prmat@mail.osu.ru

DOI: <https://doi.org/10.17816/DD623196>

Применение искусственного интеллекта в диагностике кальцификации артерий

Ю.А. Трусов¹, В.С. Чупахина², А.С. Нуркаева³, Н.А. Яковенко⁴, И.В. Абленина⁵,
Р.Ф. Латыпова⁵, А.П. Питке⁵, А.А. Язовских³, А.С. Иванов³, Д.С. Богатырева⁶,
У.А. Попова⁷, А.Ф. Юзлекбаев³

¹ Самарский государственный медицинский университет, Самара, Россия;

² Ростовский государственный медицинский университет, Ростов-на-Дону, Россия;

³ Башкирский государственный медицинский университет, Уфа, Россия;

⁴ Первый Московский государственный медицинский университет им. И.М. Сеченова, Москва, Россия;

⁵ Оренбургский государственный медицинский университет, Оренбург, Россия;

⁶ Российский национальный исследовательский медицинский университет им. Н.И. Пирогова, Москва, Россия;

⁷ Российский университет медицины, Москва, Россия

АННОТАЦИЯ

Обоснование. Показатели заболеваемости населения Российской Федерации патологиями системы кровообращения за прошедшие два десятилетия постоянно повышались, и с 2000 г. до 2019 г. увеличились в 2,047 раза. Процесс кальцификации сосудов включает отложение солей кальция в стенке артерий, что приводит к ремоделированию сосудистой стенки. Лучевые методы исследования — золотой стандарт диагностики кальцификации сосудов. Однако в связи с возрастающим объёмом данных и необходимостью сокращения времени постановки диагноза неизбежно снижается эффективность работы. Активное развитие и внедрение в клиническую практику искусственного интеллекта открыло перед специалистами возможности для решения этих проблем.

Цель — проанализировать отечественную и зарубежную литературу, посвящённую использованию искусственного интеллекта в диагностике различных типов кальцификации сосудов, а также обобщить прогностическую ценность кальцификации сосудов и оценить аспекты, препятствующие диагностике кальцификации сосудов без применения искусственного интеллекта.

Материалы и методы. Авторы провели поиск публикаций в электронных базах данных PubMed, Web of Science, Google Scholar и eLibrary. Поиск проводился по следующим ключевым словам: «artificial intelligence», «machine learning», «vascular calcification», «искусственный интеллект», «машинное обучение», «кальцификация сосудов». Поиск проводился во временном интервале с момента основания соответствующей базы данных до июля 2023 года.

Результаты. Основная методология включённых в обзор исследований заключалась в сравнении диагностических способностей клиницистов и искусственного интеллекта с применением одних и тех же изображений и последующей оценкой точности, скорости и других показателей. Участки возникновения сосудистых кальцификаций весьма разнообразны, что обуславливает их различную прогностическую ценность.

Заключение. Искусственный интеллект отлично зарекомендовал себя в диагностике сосудистой кальцификации. Помимо повышения точности и эффективности, способности к детализации превосходят возможности ручного метода диагностики. Искусственный интеллект достиг уровня, позволяющего помогать врачам инструментальной диагностики в автоматическом выявлении кальцификации сосудов. Возможности искусственного интеллекта могут способствовать эффективному развитию рентгенологии в будущем.

Ключевые слова: искусственный интеллект; машинное обучение; кальцификация сосудов; рентгенология; диагностическая визуализация.

Как цитировать:

Трусов Ю.А., Чупахина В.С., Нуркаева А.С., Яковенко Н.А., Абленина И.В., Латыпова Р.Ф., Питке А.П., Язовских А.А., Иванов А.С., Богатырева Д.С., Попова У.А., Юзлекбаев А.Ф. Применение искусственного интеллекта в диагностике кальцификации артерий // Digital Diagnostics. 2024. Т. 5, № 1. С. 85–100. DOI: <https://doi.org/10.17816/DD623196>

DOI: <https://doi.org/10.17816/DD623196>

Use of artificial intelligence in the diagnosis of arterial calcification

Yuri A. Trusov¹, Victoria S. Chupakhina², Adilya S. Nurkaeva³, Natalia A. Yakovenko⁴, Irina V. Ablenina⁵, Roksana F. Latypova⁵, Aleksandra P. Pitke⁵, Anastasiya A. Yazovskih³, Artem S. Ivanov³, Darya S. Bogatyreva⁶, Ulyana A. Popova⁷, Azat F. Yuzlekbaev³

¹ Samara State Medical University, Samara, Russia;

² Rostov State Medical University, Rostov-on-Don, Russia;

³ Bashkir State Medical University, Ufa, Russia;

⁴ Sechenov First Moscow State Medical University, Moscow, Russia;

⁵ Orenburg State Medical University, Orenburg, Russia;

⁶ Russian National Research Medical University named after N.I. Pirogov, Moscow, Russia;

⁷ Russian University of Medicine, Moscow, Russia

ABSTRACT

BACKGROUND: The incidence of circulatory system diseases in the Russian Federation has been steadily increasing during the last two decades, growing 2,047 times between 2000 and 2019. Vascular calcification involves the deposition of calcium salts in the artery wall, which leads to vascular wall remodeling. X-ray imaging is the gold standard for diagnosing of vascular calcification. However, because of the need to process an increasing amount of data in a shorter period of time, the number of diagnostic errors inevitably increases, and work efficiency inevitably decreases. The active development and introduction of artificial intelligence into clinical practice have created opportunities for specialists to address these issues.

AIM: To analyze the national and international literature on the use of artificial intelligence in the diagnosis of various vascular calcifications, summarize the prognostic value of vascular calcification, and evaluate aspects that prevent the diagnosis of vascular calcification without using artificial intelligence.

MATERIALS AND METHODS: A search was performed in PubMed, Web of Science, Google Scholar, and eLibrary. The search was conducted using the following keywords: artificial intelligence, machine learning, vascular calcification, and their analogues in Russian. The search covered the period from inception till July 2023.

RESULTS: The studies included in the review compared the diagnostic abilities of clinicians and artificial intelligence using the same images, with subsequent assessment of the accuracy, speed, and other parameters. The sites of vascular calcification varied, resulting in differences in their prognostic value.

CONCLUSION: Artificial intelligence has proven to be effective in the diagnosis of vascular calcification. In addition to improved accuracy and efficiency, the level of detail is superior to manual diagnosis methods. Artificial intelligence has advanced to the point that imaging specialists can automatically detect vascular calcification. Artificial intelligence can contribute to the successful development of X-ray imaging in the future.

Keywords: artificial intelligence; machine learning; vascular calcification; radiology; diagnostic imaging.

To cite this article:

Trusov YuA, Chupakhina VS, Nurkaeva AS, Yakovenko NA, Ablenina IV, Latypova RF, Pitke AP, Yazovskih AA, Ivanov AS, Bogatyreva DS, Popova UA, Yuzlekbaev AF. Use of artificial intelligence in the diagnosis of arterial calcification. *Digital Diagnostics*. 2024;5(1):85–100. DOI: <https://doi.org/10.17816/DD623196>

DOI: <https://doi.org/10.17816/DD623196>

人工智能在动脉钙化诊断中的应用

Yuri A. Trusov¹, Victoria S. Chupakhina², Adilya S. Nurkaeva³, Natalia A. Yakovenko⁴,
Irina V. Ablenina⁵, Roksana F. Latypova⁵, Aleksandra P. Pitke⁵, Anastasiya A. Yazovskih³,
Artem S. Ivanov³, Darya S. Bogatyreva⁶, Ulyana A. Popova⁷, Azat F. Yuzlekbaev³

¹ Samara State Medical University, Samara, Russia;

² Rostov State Medical University, Rostov-on-Don, Russia;

³ Bashkir State Medical University, Ufa, Russia;

⁴ Sechenov First Moscow State Medical University, Moscow, Russia;

⁵ Orenburg State Medical University, Orenburg, Russia;

⁶ Russian National Research Medical University named after N.I. Pirogov, Moscow, Russia;

⁷ Russian University of Medicine, Moscow, Russia

摘要

论证。近二十年来，俄罗斯联邦居民循环系统疾病的发病率持续上升。从2000年到2019年，此类疾病的数量增加了2.047倍。血管钙化过程包括钙盐在动脉壁的沉积，这导致血管壁重塑。放射性检查方法是诊断血管钙化的金标准。然而，随着数据量的增加和诊断时间的需要，工作效率不可避免地下降，人工智能的积极发展和应用于临床为专家解决这些问题提供了机会。

目的。本研究的目的是分析国内外关于使用人工智能诊断不同类型血管钙化的文献，同时，总结血管钙化的预后价值，并评估在不使用人工智能的情况下阻碍血管钙化诊断的方面。

材料与方法。在电子数据库PubMed、Web of Science、Google Scholar和eLibrary中搜索了相关出版物。搜索时使用了以下关键词：“artificial intelligence”，“machine learning”，“vascular calcification”，“人工智能”、“机器学习”、“血管钙化”。检索时间为相关数据库建立至2023年7月。

结果。综述中包含的研究的主要方法是比较临床医生和人工智能使用相同图片的诊断能力，然后评估准确性、速度和其他指标。血管钙化发生的部位差异很大，这也是其预后价值不同的原因。

结论。事实证明，人工智能在诊断血管钙化方面表现出色。除了提高准确性和效率外，其细节处理能力也超过人工诊断方法。人工智能已经达到了帮助仪器诊断医生自动检测血管钙化的水平。未来，人工智能的能力可以促进放射学的有效发展。

关键词：人工智能；机器学习；血管钙化；放射学；诊断成像。

引用本文：

Trusov YuA, Chupakhina VS, Nurkaeva AS, Yakovenko NA, Ablenina IV, Latypova RF, Pitke AP, Yazovskih AA, Ivanov AS, Bogatyreva DS, Popova UA, Yuzlekbaev AF. 人工智能在动脉钙化诊断中的应用. *Digital Diagnostics*. 2024;5(1):85–100. DOI: <https://doi.org/10.17816/DD623196>

收到: 10.11.2023

接受: 10.01.2024

发布日期: 29.01.2024

ОБОСНОВАНИЕ

Показатели заболеваемости населения Российской Федерации патологиями системы кровообращения за прошедшие два десятилетия постоянно повышались, и с 2000 г. до 2019 г. увеличились в 2,047 раза [1]. Процесс кальцификации сосудов включает отложение солей кальция в стенке артерий, что приводит к ремоделированию сосудистой стенки [2]. Кальцификация интимы носит очаговый характер и ассоциируется с атеросклерозом, в то время как кальцификация медики носит диффузный характер и лежит в патогенезе таких заболеваний, как сахарный диабет, заболевания периферических артерий, а также хроническая болезнь почек [3]. Лучевые методы исследования — золотой стандарт диагностики кальцификации сосудов [4]. Однако в связи с возрастающим объёмом данных и необходимостью сокращения времени постановки диагноза неизбежно снижается эффективность работы [5]. Данные обстоятельства способствуют поиску новых аспектов для улучшения качества работы врачей инструментальной диагностики.

Активное развитие и внедрение в клиническую практику искусственного интеллекта (ИИ) открыло перед специалистами возможности для решения этих проблем [6]. Исходя из анализа имеющихся литературных данных, до настоящего времени ИИ применялся для рентгенодиагностики 5 типов кальцификации сосудов: кальцификации коронарных артерий (ККА), грудной аорты (КГА), брюшной аорты (КБА), сонных артерий (КСА) и маммарных артерий (КМА).

Цель исследования — проанализировать отечественную и зарубежную литературу, посвящённую использованию ИИ в диагностике различных типов кальцификации сосудов, а также обобщить прогностическую ценность кальцификации

сосудов и оценить аспекты, препятствующие диагностике кальцификации сосудов без применения ИИ.

МАТЕРИАЛЫ И МЕТОДЫ

Авторы провели поиск публикаций в электронных базах данных PubMed, Web of Science, Google Scholar и eLibrary. Поиск проводился по следующим ключевым словам: «artificial intelligence», «machine learning», «vascular calcification», «искусственный интеллект», «машинное обучение», «кальцификация сосудов». Поиск проводился во временном интервале с момента основания соответствующей базы данных до июля 2023 года. Авторы независимо друг от друга провели анализ заголовков и аннотаций статей, после чего извлекался полный текст релевантных исследований. Кроме того, анализу подвергали списки литературы релевантных исследований.

РЕЗУЛЬТАТЫ

Основная методология включённых в обзор исследований заключалась в сравнении диагностических способностей клиницистов и ИИ с применением одних и тех же изображений и последующей оценкой точности, скорости и других показателей.

Участки возникновения сосудистых кальцификаций весьма разнообразны, что обуславливает их различную прогностическую ценность. В табл. 1 кратко представлена прогностическая ценность кальцификации сосудов в зависимости от локализации.

Кальцификация коронарных артерий

Один из инструментов прогнозирования сердечно-сосудистого риска — Фрамингемская шкала, которая

Таблица 1. Прогностическая ценность кальцификации сосудов в зависимости от локализации

Тип кальцификации сосудов	Прогностическое значение
Кальцификация коронарных артерий	– маркёр выраженности атеросклероза коронарных артерий; – оценка риска развития сердечно-сосудистых заболеваний по Фрамингемской шкале; – предиктор ИБС; – маркёр кардиотоксичности при химиотерапии онкологических заболеваний
Кальцификация грудной аорты	– маркёр повышенного риска ИБС; – определение повышенного риска ишемического инсульта; – определение риска эмболии
Кальцификация брюшной аорты	– определение наличия обструктивной ИБС; – прогнозирование бессимптомного течения ИБС; – маркёр застойной сердечной недостаточности
Кальцификация сонных артерий	– маркёр атеросклероза сосудов головы и шеи; – определение риска развития инсульта; – прогнозирование риска развития неблагоприятных цереброваскулярных событий у молодых людей
Кальцификация маммарных артерий	– определение риска сердечно-сосудистых событий у лиц женского пола; – ассоциация с хронической болезнью почек, сахарным диабетом и заболеваниями костей

Примечание. ИБС — ишемическая болезнь сердца.

подразумевает оценку таких факторов риска, как возраст, пол и артериальное давление [7]. Однако в крупном проспективном исследовании с последующим наблюдением в течение 7 лет сообщалось, что ККА, диагностированная с помощью компьютерной томографии (КТ), может улучшить прогноз риска, полученный только с использованием Фрамингемской шкалы. М.Н. Criqui и соавт. в исследовании с периодом наблюдения 7,6 года показали, что оценка выраженности ККА, основанная на показателях объёма и плотности сосуда, обладает хорошей прогностической ценностью [8]. Показатель объёма ККА положительно коррелировал с риском развития ишемической болезни сердца (ИБС), в то время как показатель плотности ККА демонстрировал отрицательную корреляцию [8].

Степень ККА определяется путём перемножения интеграла плотности кальцифицированных бляшек и площади кальцификации. Общее значение ККА представляет собой сумму результатов, рассчитанных на каждом уровне. Общеизвестно, что пожилые люди — основная группа риска развития ИБС [1]. Однако 12,5-летнее исследование показало, что лица в возрасте от 32 до 46 лет даже при низкой степени выраженности ККА имели повышенный риск развития ИБС и смерти [9]. Анализируя результаты данных исследований, можно сделать вывод, что информация, связанная с ККА, обладает высокой прогностической ценностью для определения риска сердечно-сосудистых событий практически во всех возрастных группах. Взаимосвязь между степенью ККА и риском развития неблагоприятных сердечно-сосудистых событий представлена в табл. 2.

Кальцификация грудной аорты

Известно, что КГА широко распространена в популяции пациентов с гипертонической болезнью [10]. Кроме того, неоднократно выявлялась связь между КГА и повышенным риском ИБС и смерти [10, 11]. На основании исследования, включавшего 2618 человек, Y. Itani и соавт. установили, что КГА — эффективное средство оценки риска развития ишемического инсульта [12]. В исследовании, проведённом на пациентах, имеющих показания

к проведению сердечно-сосудистых операций, R. Lee и соавт. выявили, что предоперационный КТ-скрининг состояния КГА позволяет выявить зоны повышенного риска и снизить вероятность аортальной эмболии и инсульта [13]. Таким образом, степень КГА позволяет не только прогнозировать риск развития сердечно-сосудистых катастроф, но и способствовать выявлению цереброваскулярных изменений.

Кальцификация брюшной аорты

В исследовании, проведённом с участием 58 пациентов, было обнаружено, что показатель КБА, оценённый с использованием КТ, коррелирует со степенью выраженности ККА. Отсутствие КБА, в свою очередь, позволяет исключить ИБС [14]. Кроме того, было показано, что КБА может быть использована в качестве дополнительного диагностического инструмента бессимптомного течения ИБС и независимого фактора риска развития застойной сердечной недостаточности [15, 16]. Известно также, что КБА имеет важное прогностическое значение по отношению к костной системе. Y.Z. Bagger и соавт. провели исследование, включавшее 2662 здоровых женщины, находящихся в постменопаузе. Результаты исследования показали, что КБА коррелирует с повышением риска развития остеопороза проксимального отдела бедренной кости [17]. Кроме того, исследование P. Szulc и соавт., включавшее 5994 мужчины возрастом 65 лет, подтвердило, что наличие КБА коррелирует с повышенным риском перелома бедренной кости у пожилых мужчин [18].

Кальцификация сонных артерий

КСА — важный предиктор цереброваскулярных заболеваний [19]. Кальцификация интракраниального отдела внутренних сонных артерий (КИК) служит важным маркёром внутричерепной гипертензии у представителей различных этнических групп и тесно связана с риском развития инсульта [19–21]. Примечательно, что исследование, включавшее около 2000 пациентов, показало, что КИК широко распространена у лиц молодого возраста. Однако неясно, является ли КИК в молодом возрасте сходной с патологией, возникающей в более старшем возрасте, и, следовательно, может ли увеличивать риск развития инсульта в будущем [22].

Кальцификация артерий молочной железы

В исследовании, включавшем 213 пациенток, Z. Huang и соавт. выявили, что КМА коррелирует с ККА и тяжестью ИБС [23]. Е.В. Бочкарева и соавт. проанализировали 4274 цифровые маммограммы женщин в возрастном диапазоне 40–93 лет. Авторы выявляли статистически значимую сильную корреляцию между возрастом женщины и наличием КМА [24]. Другие работы Е.В. Бочкаревой и соавт. наглядно продемонстрировали, что КМА связана с развитием хронической болезни почек, сахарного диабета, цереброваскулярных заболеваний, а также

Таблица 2. Взаимосвязь между степенью кальцификации коронарных артерий и риском развития неблагоприятных сердечно-сосудистых событий

Оценка кальцификации коронарных артерий	Риск кальцификации
0	Отсутствует
1–10	Низкий
11–100	Средний
101–400	Выше среднего
>401	Высокий

с нарушением минеральной плотности костной ткани [25–27]. К сожалению, пациенты женского пола имеют недостаточное представление о сердечно-сосудистых заболеваниях, которые являются одной из наиболее серьёзных угроз для здоровья женщин [28]. Таким образом, учитывая факт доступности оценки КМА и её диагностической ценности, отражающей сердечно-сосудистый риск у женщин, врачи инструментальной диагностики должны уделять должное внимание данной проблеме.

Трудности инструментальной диагностики кальцификации сосудов

Анализ развития службы лучевой диагностики в Российской Федерации за 2014–2019 гг. показал, что объём медицинских изображений ежегодно растёт, и врачам отделений инструментальной диагностики приходится интерпретировать изображения каждые 3–4 секунды в течение 8-часового рабочего дня [29]. Исследование физического состояния 40 специалистов инструментальной диагностики до и после рабочего дня показало, что после работы в течение 1 дня значительно снижается концентрация внимания и усиливаются симптомы астенопатии [30]. По имеющимся данным, 75% исков, касающихся дефектов оказания медицинской помощи среди врачей инструментальной диагностики связаны с диагностическими ошибками [31].

Точное определение степени кальцификации сосудов — сложная задача. Форма кальцифицированных очагов изменчива и подвержена различным нарушениям. Например, с целью диагностики ККА используются различные модификации КТ [32], однако они требуют дополнительного оснащения, что увеличивает экономическую нагрузку на медицинскую организацию, а также лучевую нагрузку на пациента (которая может быть снижена, если установить диагноз с помощью стандартных методов). Кроме того, не во всех случаях врачи-рентгенологи оценивают отражённую на снимках сосудистую кальцификацию, что может использоваться для косвенной оценки кальциноза коронарного русла, но золотым стандартом является КТ с кардиосинхронизацией и определённой областью исследования (FOV) [33, 34].

Роль искусственного интеллекта в оценке кальцификации артерий

Кальцификация коронарных артерий

Впервые автоматическое определение степени ККА с помощью ИИ было проведено в 2007 году. Для каждого кандидата было разработано 64 признака, после чего был применён метод кластеризации ближайших соседей, являющийся метрическим алгоритмом для автоматической классификации объектов или регрессии, который позволил достичь точности 73,8% [35]. В последующие годы активно изучались различные методы проектирования характеристик, включая пространственные и геометрические [36–38]. Поскольку выбор объектов на изображениях,

полученных с использованием неконтрастной КТ, вызывает технические сложности, более популярным методом стала регистрация информации, полученной с использованием изображений КТ с определением коронарного кальция [39–41]. Для определения коронарного кальциноза принято использовать электрокардиографическую (ЭКГ) синхронизацию для получения изображения в диастолическую фазу, с последующей реконструкцией «сшиванием» изображений. Алгоритм, использующий машину опорных векторов, достиг чувствительности 98,9% и прогностической ценности 94,8% [42]. Подобные алгоритмы машинного обучения активно применялись до 2016 года, но ввиду необходимости ручного управления их применение было сопряжено с определёнными трудностями [42].

Для дальнейшего повышения эффективности в качестве основного варианта была выбрана искусственная нейронная сеть (ИНС) с глубоким обучением (ГО) [43]. Первоначально эффективность ГО была неудовлетворительной, однако благодаря постоянному совершенствованию ИНС исследователям удалось добиться повышения эффективности, точного, автоматического подсчёта баллов [44–51].

B.D. de Vos и соавт. в исследовании по определению ККА выявили, что результаты, полученные с использованием ГО, практически полностью совпали с результатами, рассчитанными вручную, а определение индекса Агатстона (золотой стандарт КТ-метода подсчёта кальция в клинической практике) было выполнено менее чем за 0,3 секунды [52].

Алгоритм U-Net является расширением ИНС, целью которого служит достижение более эффективного обучения с использованием меньшего количества ресурсов [53]. N. Gogin и соавт. в проведённом исследовании подтвердили эффективность ГО на основе архитектуры U-Net, производительность которой оказалась очень близка к показателям других алгоритмов [46]. U-Net правильно классифицировала риски в 86% случаев. Важно отметить, что применение U-Net позволяет напрямую вводить изображение без потери пиксельной информации [49].

КТ с ЭКГ-синхронизацией получила менее широкую распространённость в мире по сравнению с КТ без применения ЭКГ [54]. В случае повышения достоверности информации о ККА, полученной без применения ЭКГ, возможно сократить количество КТ-исследований, снизить экономические затраты и уменьшив лучевую нагрузку [55]. Наличие большого количества помех и артефактов значительно снижает точность ручного определения ККА с помощью КТ без ЭКГ [56].

ИИ сыграл большую роль в диагностике ККА с применением КТ без ЭКГ. I. Isgum и соавт. более 10 лет назад выявили, что алгоритмы машинного обучения позволяют достичь точности, равной 82,2%, в оценке по шкале Агатстона при использовании низкодозовой КТ грудной клетки [57]. Многие исследователи стремились нивелировать уровень помех и артефактов, а также уменьшить влияние

некальцифицированных компонентов (стенты) на диагностику. Разработанные ими алгоритмы ГО позволили повысить ценность изображений низкого качества [58, 59]. Z. Sun и соавт. продемонстрировали, что алгоритмы ГО улучшали соотношение сигнал/шум низкодозовой КТ на 27,7%, а специфичность выявления ККА увеличилась на 41% за счёт удаления артефактов [60]. Важно отметить, что доля случаев правильной интерпретации КТ без ЭКГ составила всего 70%, однако коэффициент корреляции между результатами с применением ИИ и ручного анализа составил 0,923 [56].

В другом исследовании, проведённом В. Yasoub и соавт., было установлено, что при выявлении ККА на не-контрастной КТ грудной клетки чувствительность, специфичность и площадь под кривой (AUC), полученные с применением ИИ, превосходят результаты, полученные вручную. Это позволяет предположить, что эффективность применения ИИ при проведении КТ без ЭКГ может быть выше, чем при человеческой оценке [34]. Кроме того, в одном из исследований эффективность ИИ с применением КТ без ЭКГ была подтверждена в 4 различных центрах. Во всех выборках были получены высокие показатели чувствительности и положительная прогностическая ценность, что повышает качество полученных результатов [61]. Следует отметить, что в настоящее время применение ИИ в диагностике ККА на основе КТ без ЭКГ является достоверным методом оценки данных.

Примечательно, что исследователи начали применять возможности ИИ по диагностике ККА и на других устройствах — например, при анализе рентгенограммы грудной клетки [62]. P.I. Kamel и соавт. разработали классификацию суммарных показателей кальция на рентгенограммах грудной клетки с использованием глубокой ИНС, что продемонстрировало возможность снижения применения КТ у ряда пациентов [63]. При этом для выявления ККА в этом исследовании AUC достигла 0,73 и 0,7 на снимках в переднезадней и боковой проекциях соответственно. Кроме того, в одном из исследований была предложена нейронная сеть, позволяющая в течение нескольких секунд анализировать изображения, полученные при инвазивной коронарной ангиографии, и выявлять ККА с коэффициентом F1, равным 0,802 [64].

Кальцификация грудной аорты

По сравнению с ККА точность выявления КГА при КТ не зависит от интенсивности сокращения сердца [65]. Например, I. Isgit и соавт. выявили КГА в 97,9% случаев с использованием метода k-ближайших соседей, что коррелировало с результатами, полученными при ручном исследовании [65]. В последние годы применение ГО позволило одновременно определять ККА и КГА [66]. Аналогичной позиции придерживаются S.G.M. van Velzen и соавт., применившие описанные методы к различным видам КТ (включая КТ с определением коронарного кальция, низкодозную КТ грудной клетки

и позитронно-эмиссионную КТ), при этом коэффициент внутриклассовой корреляции варьировал от 0,68 до 0,98 [67]. Следует отметить, что в исследовании с использованием свёрточной нейронной сети для обнаружения КГА была достигнута чувствительность 98,4%, что позволило не только дифференцировать КГА в восходящей и нисходящей частях аорты, а также в её дуге, но и определить выраженность риска [68]. Таким образом, применение ИИ с автоматической оценкой ККА и КГА является неотъемлемой частью работы врачей-рентгенологов.

Кальцификация брюшной аорты

Благодаря прогрессу в области ГО была реализована возможность автоматического определения КБА, что было подтверждено в двух исследованиях [69, 70]. Двухэнергетическая рентгеновская абсорбциометрия — метод диагностики, позволяющий оценить риски возникновения переломов. Рост использования этого метода открывает возможности для применения автоматизации оценки КБА, однако в силу технических сложностей он не используется для рутинного выявления КБА. S. Reid и соавт. классифицировали КБА с помощью свёрточной нейронной сети на основе денситометрии, достигнув высокой степени соответствия с результатами, полученными вручную, а показатель Карра составил 0,71 [69]. Стоит отметить, что по сравнению с двухэнергетической рентгеновской абсорбциометрией КТ демонстрирует очевидные преимущества в количественной оценке кальцификации аорты. P.M. Graffy и соавт. удалось успешно реализовать автоматическое выявление КБА с применением КТ брюшной полости у более чем 9000 пациентов, объясняя это применением Mask Region-based Convolutional Neural Network [70]. На основе количественных данных в рамках этого исследования также была проведена оценка распространённости КБА, что повышает значимость ИИ.

Подводя итог, можно сказать, что автоматическая количественная оценка КБА может быть реализована с применением ИИ, однако количество имеющихся данных резко ограничено.

Кальцификация сонных артерий

Кальцификация как экстракраниального, так и интракраниального отделов внутренних сонных артерий могут быть диагностированы при использовании КТ с ИИ [71–73]. G. Bortsova и соавт. в проведённом исследовании использовали 4 сети ГО со структурой, аналогичной U-Net, при этом точность обнаружения КИК оказалась выше, чем при ручной оценке, — с чувствительностью 83,8% и прогностической ценностью 88% [73]. Ручная оценка КИК требует тщательного анализа, а также чревата ошибками и подвержена риску появления схожих структур (например, костные кальцификаты). Ввиду этого большое значение имеет высокая точность, демонстрируемая ГО.

Наиболее существенные отличия КСА от других сосудистых кальцификаций может выявить магнитно-резонансная

томография (MPT) [71]. В более ранних исследованиях точность выявления кальцификации при использовании MPT была низкой [71]. Однако применение SNAP (simultaneous non-contrast angiography and intraplaque hemorrhage) позволило улучшить способность распознавания кальцификации с использованием MPT. При использовании SNAP все сигналы инвертируются инверсионным импульсом, после чего выполняется T1-взвешенное восстановление инверсии и контрольное сканирование, взвешенное по протонной плотности с помощью двухградиентного эхо, что даёт отличный эффект при визуализации сосудов черепа и шейного отдела позвоночника [74]. Несмотря на то, что SNAP успешно выявляет кальцификацию, он подвержен влиянию артефактов при движении, а время проведения исследования относительно велико. Данная проблема может быть решена с помощью Goal-SNAP и быстрого SNAP [75, 76]. В данном исследовании такие алгоритмы машинного обучения, как метод случайного леса, схожи с ИНС в отношении обнаружения кальцификации, но ГО может быть эффективнее по отношению к сегментированию сосудистых компонентов, что требует проведения дальнейших исследований.

Кальцификация артерий молочной железы

КМА визуализируется на маммограммах, однако проявления кальцификации весьма разнообразны. Они могут быть раздвоенными, перекрытыми, усечёнными, а также иметь различную интенсивность [77]. Такая сложность затрудняет ручную количественную оценку КМА.

Маммография, являясь методом лучевой диагностики, который применяют для скрининга, нацеленного на выявление рака молочной железы, введена в объём профилактического медицинского осмотра и диспансеризации с 2012 г. Ежегодно частота проведения этого исследования, соответственно регламентам Министерства здравоохранения Российской Федерации, увеличивается [78].

В отношении данного вопроса ряд авторов рассматривает применение ГО. Было предложено нарезать маммограммы на участки, что необходимо ввиду большого объёма данных для прямого ввода [53]. 12-слойная свёрточная нейронная сеть описывает обнаружение КМА как задачу второго порядка [28]. Несмотря на то, что она успешно различала наличие или отсутствие КМА, количественная оценка её результатов была недостаточна точной [28]. Кроме того, анализ и обработка данных проводились достаточно медленно из-за необходимости отдельной обработки каждого участка. Впоследствии исследователи усовершенствовали свёрточную нейронную сеть с учётом описанных недостатков, предложив использовать простую контекстную U-сеть (SCU-Net) и плотную U-сеть (DU-Net) [33, 53]. SCU-Net — это упрощённая версия U-Net, которая преодолевает проблему, связанную с тем, что на КМА приходится менее 1% изображений, тем самым создавая большое количество данных и нарушая эффективное обучение системы. DU-Net также позволяет

избежать данной проблемы, значительно повышая эффективность свёрточной нейронной сети, и имеет точность 91,47% и чувствительность 91,22% [53].

Подводя итог, можно сказать, что ГО, используемое для автоматического определения КМА, достигло высокого уровня, однако не существует надёжного общедоступного набора данных для унификации в этой области, поэтому необходимо продолжать исследования в данном направлении.

ОБСУЖДЕНИЕ

Как было отмечено выше, ИИ может облегчить и улучшить деятельность врачей инструментальной диагностики по вопросам кальцификации сосудов, выполняя предварительный скрининг и повышая эффективность обработки данных.

Точность применения ИИ в диагностической рентгенологии связана с алгоритмами ИИ и характеристикой изображений. Эффективность деятельности алгоритмов машинного обучения и ГО достигла значительного прогресса, что способствует улучшению диагностической ценности данных методик. По мере развития технологий визуализации качество изображений постоянно улучшалось, что положительно сказалось на эффективности диагностики. Возможности ИИ связаны с высоким качеством баз данных, необходимых для обучения, что также может быть полезно при создании общедоступных баз данных или тестовых платформ. Таким образом, в будущем инженеры и врачи должны стремиться к развитию диагностических возможностей ИИ, основываясь на самом алгоритме ИИ и качестве изображений.

Важно отметить, что хотя ИИ показал удовлетворительный результат при 5 типах сосудистой кальцификации, он имеет потенциальную ценность и при таком типе обызвествления, как кальцификация почечных артерий, прогностическая ценность которой при артериальной гипертензии и протеинурии была подтверждена [79]. В то же время количество исследований, посвящённых КБА и КСА невелико, что вызывает ещё больший интерес относительно их изучения. Сравнение эффективности ИИ в диагностике каждого типа кальцификации сосудов представлено в табл. 3.

ЗАКЛЮЧЕНИЕ

ИИ отлично зарекомендовал себя в диагностике сосудистой кальцификации. Помимо повышения точности и эффективности, способности к детализации превосходят возможности ручного метода диагностики. ИИ достиг уровня, позволяющего помогать врачам инструментальной диагностики в автоматическом выявлении кальцификации сосудов. Возможности ИИ могут способствовать эффективному развитию рентгенологии в будущем.

Таблица 3. Сравнение результатов применения искусственного интеллекта в диагностике 5 типов кальцификации сосудов

Тип сосудистой кальцификации	Количество исследований	Применение рентгенографии	Применение КТ	Применение МРТ	Применение ГО
Кальцификация коронарных артерий	Большое	Да	Да	Нет	Пиксельная и сквозная ГО в сочетании с ГАН снижает уровень помех и артефактов, что делает надёжной автоматическую оценку ККА и позволяет достоверно оценить результаты
Кальцификация грудной аорты	Среднее	Нет	Да	Нет	ГО обеспечивает автоматическое определение КГА и КСА, позволяя оценивать результаты на разных участках аорты
Кальцификация брюшной аорты	Малое, требуется большее количество исследований	Да	Да	Нет	Такие методы ГО, как Mask Region-CNN, позволяют проводить точную количественную оценку КБА при использовании ДРА и КТ
Кальцификация сонных артерий	Малое, требуется большее количество исследований	Нет	Да	Да	Эффективность ГО, по-видимому, близка к эффективности МО и превосходит возможности человека с дополнительной возможностью использования МРТ
Кальцификация маммарных артерий	Среднее	Да	Нет	Нет	U-Net, SCU-Net, DU-Net и другие усовершенствованные системы ГО способствуют выявлению КМА

Примечание. ГАН — генеративно-сопоставительная сеть; ГО — глубокое обучение; ДРА — двухэнергетическая рентгеновская абсорбциометрия; КБА — кальцификация брюшной аорты; КГА — кальцификация грудной аорты; ККА — кальцификация коронарных артерий; КМА — кальцификация маммарных артерий; КТ — компьютерная томография; МО — машинное обучение; МРТ — магнитно-резонансная томография; Mask Region-CNN — Mask Region-based Convolutional Neural Network; SCU-Net — простая контекстная U-сеть; DU-Net — плотная U-сеть.

ДОПОЛНИТЕЛЬНАЯ ИНФОРМАЦИЯ

Источник финансирования. Авторы заявляют об отсутствии внешнего финансирования при проведении исследования.

Конфликт интересов. Авторы декларируют отсутствие явных и потенциальных конфликтов интересов, связанных с публикацией настоящей статьи.

Вклад авторов. Все авторы подтверждают соответствие своего авторства международным критериям ICMJE (все авторы внесли существенный вклад в разработку концепции, проведение исследования и подготовку статьи, прочли и одобрили финальную версию перед публикацией).

Наибольший вклад распределён следующим образом: Ю.А. Трусов, В.С. Чупахина — разработка концепции и дизайна исследования, научное редактирование рукописи; А.С. Нуркаева — анализ и поиск данных, написание текста рукописи; Н.А. Яковенко — анализ данных, написание текста рукописи; И.В. Абленина — анализ данных, редактирование текста рукописи; Р.Ф. Латыпова — анализ данных, проверка и утверждение текста; А.П. Питке — написание текста рукописи, получение

фактических данных; А.А. Язовских — редактирование текста статьи, анализ данных; А.С. Иванов — получение данных, написание текста статьи; Д.С. Богатырева — утверждение финального варианта рукописи, редактирование текста статьи; У.А. Попова — анализ данных, написание текста статьи; А.Ф. Юзлекбаев — анализ и получение данных.

ADDITIONAL INFORMATION

Funding source. This study was not supported by any external sources of funding.

Competing interests. The authors declare that they have no competing interests.

Authors' contribution. All authors made a substantial contribution to the conception of the work, acquisition, analysis, interpretation of data for the work, drafting and revising the work, final approval of the version to be published and agree to be accountable for all aspects of the work. Yu.A. Trusov, V.S. Chupakhina — development of the concept and design of the study, scientific revision of the manuscript; A.S. Nurkaeva — data analysis and search, writing

the manuscript; N.A. Yakovenko — data analysis, writing the manuscript; I.V. Ablenina — data analysis, editing the text of the manuscript; R.F. Latypova — data analysis, verification and approval of the text; A.P. Pitke — writing a manuscript, obtaining factual data; A.A. Yazovskikh — editing the text of the article, analyzing

data; A.S. Ivanov — obtaining data, writing the text of the article; D.S. Bogatyreva — approval of the final version of the manuscript, editing of the text of the article; U.A. Popova — data analysis, participation in the writing of the article; A.F. Yuzlekbayev — analysis and data acquisition.

СПИСОК ЛИТЕРАТУРЫ

1. Шарапова О.В., Кича Д.И., Герасимова Л.И., и др. Картографический анализ показателей заболеваемости и смертности от болезней системы кровообращения населения Российской Федерации (2010–2019 гг.) // Комплексные проблемы сердечно-сосудистых заболеваний. 2022. Т. 11, № 1. С. 56–68. EDN: ZUQVNA doi: 10.17802/2306-1278-2022-11-1-56-68
2. Мальков О.А., Говорухина А.А., Бурыкин Ю.Г., Афинеевская А.Ю. Роль кальцификации в патогенезе воспалительной реакции артериальной стенки (на примере сосудов шеи и головы взрослого населения) // Журнал медико-биологических исследований. 2021. Т. 9, № 4. С. 435–443. EDN: FTSKDS doi: 10.37482/2687-1491-Z081
3. Арчакова Т.В., Недосугова Л.В. Факторы кальцификации сосудов у пациентов с сахарным диабетом 2 типа, получающих лечение программным гемодиализом // Сахарный диабет. 2020. Т. 23, № 2. С. 125–131. EDN: KPXIVL doi: 10.14341/DM10145
4. Mori H, Torii S, Kutyna M, et al. Coronary Artery Calcification and its Progression: What Does it Really Mean? // JACC Cardiovasc Imaging. 2018. Vol. 11, N 1. P. 127–142. doi: 10.1016/j.jcmg.2017.10.012
5. Йоо К.К. Искусственный интеллект в кардиологии: сработал ли он? // Российский журнал персонализированной медицины. 2022. Т. 2, № 6. С. 16–22. EDN: UIENOT doi: 10.18705/2782-3806-2022-2-6-16-22
6. Карпов О.Э., Андриков Д.А., Максименко В.А., Храмов А.Е. Прозрачный искусственный интеллект для медицины // Врач и информационные технологии. 2022. № 2. С. 4–11. EDN: DTCAWX doi: 10.25881/18110193_2022_2_4
7. Greenland P, LaBree L, Azen S.P., et al. Coronary artery calcium score combined with Framingham score for risk prediction in asymptomatic individuals // JAMA. 2004. Vol. 291, N 2. P. 210–215. doi: 10.1001/jama.291.2.210
8. Criqui M.H., Denenberg J.O., Ix J.H., et al. Calcium density of coronary artery plaque and risk of incident cardiovascular events // JAMA. 2014. Vol. 311, N 3. P. 271–278. doi: 10.1001/jama.2013.282535
9. Carr J.J., Jacobs D.R. Jr, Terry J.G., et al. Association of Coronary Artery Calcium in Adults Aged 32 to 46 Years With Incident Coronary Heart Disease and Death // JAMA Cardiol. 2017. Vol. 2, N 4. P. 391–399. doi: 10.1001/jamacardio.2016.5493
10. Халиков А.А., Кузнецов К.О., Искужина Л.П., и др. Судебно-медицинские аспекты внезапной аутопсия-отрицательной сердечной смерти // Судебно-медицинская экспертиза. 2021. Т. 64, № 3. С. 59–63. doi: 10.17116/sudmed20216403159
11. Eisen A., Tenenbaum A., Koren-Morag N., et al. Calcification of the thoracic aorta as detected by spiral computed tomography among stable angina pectoris patients: association with cardiovascular events and death // Circulation. 2008. Vol. 118, N 13. P. 1328–1334. doi: 10.1161/CIRCULATIONAHA.107.712141
12. Itani Y., Watanabe S., Masuda Y. Relationship between aortic calcification and stroke in a mass screening program using a mobile helical computed tomography unit // Circ J. 2006. Vol. 70, N 6. P. 733–736. doi: 10.1253/circj.70.733
13. Lee R., Matsutani N., Polimenakos A.C., et al. Preoperative noncontrast chest computed tomography identifies potential aortic emboli // Ann Thorac Surg. 2007. Vol. 84, N 1. P. 38–42. doi: 10.1016/j.athoracsur.2007.03.025
14. Zweig B.M., Sheth M., Simpson S., Al-Mallah M.H. Association of abdominal aortic calcium with coronary artery calcium and obstructive coronary artery disease: a pilot study // Int J Cardiovasc Imaging. 2012. Vol. 28, N 2. P. 399–404. doi: 10.1007/s10554-011-9818-1
15. An C., Lee H.J., Lee H.S., et al. CT-based abdominal aortic calcification score as a surrogate marker for predicting the presence of asymptomatic coronary artery disease // Eur Radiol. 2014. Vol. 24, N 10. P. 2491–2498. doi: 10.1007/s00330-014-3298-3
16. Мельников М.В., Зелинский В.А., Жорина А.С., Чуглова Д.А. Кальцификация абдоминальной аорты при периферическом атеросклерозе: факторы риска и маркёры // Атеросклероз и дислипидемии. 2014. № 3. С. 33–38. EDN: SISNRZ
17. Bagger Y.Z., Tankó L.B., Alexandersen P., et al. Radiographic measure of aorta calcification is a site-specific predictor of bone loss and fracture risk at the hip // J Intern Med. 2006. Vol. 259, N 6. P. 598–605. doi: 10.1111/j.1365-2796.2006.01640.x
18. Szulc P., Blackwell T., Schousboe J.T., et al. High hip fracture risk in men with severe aortic calcification: MrOS study // J Bone Miner Res. 2014. Vol. 29, N 4. P. 968–975. doi: 10.1002/jbmr.2085
19. Лобанова Н.Ю., Чичерина Е.Н., Мальчикова С.В., Максимчук-Колобова Н.С. Напряжение сдвига на эндотелии стенки сонной артерии и кальциноз коронарных артерий у пациентов с гипертонической болезнью // Южно-Российский журнал терапевтической практики. 2022. Т. 3, № 3. С. 60–67. EDN: QWCOCH doi: 10.21886/2712-8156-2022-3-3-60-67
20. Kim J.T., Yoo S.H., Kwon J.H., et al. Subtyping of ischemic stroke based on vascular imaging: analysis of 1,167 acute, consecutive patients // J Clin Neurol. 2006. Vol. 2, N 4. P. 225–230. doi: 10.3988/jcn.2006.2.4.225
21. Wong L.K. Global burden of intracranial atherosclerosis // Int J Stroke. 2006. Vol. 1, N 3. P. 158–159. doi: 10.1111/j.1747-4949.2006.00045.x
22. Kockelkoren R., De Vis J.B., de Jong P.A., et al. Intracranial Carotid Artery Calcification From Infancy to Old Age // J Am Coll Cardiol. 2018. Vol. 72, N 5. P. 582–584. doi: 10.1016/j.jacc.2018.05.021
23. Huang Z., Xiao J., Xie Y., et al. The correlation of deep learning-based CAD-RADS evaluated by coronary computed tomography angiography with breast arterial calcification on mammography // Sci Rep. 2020. Vol. 10, N 1. P. 11532. doi: 10.1038/s41598-020-68378-4
24. Бочкарева Е.В., Бутина Е.К., Байрамкулова Н.Х., и др. Распространенность и степень тяжести кальциноза артерий молочной железы — нового маркёра сердечно-сосудистого риска у женщин // Рациональная Фармакотерапия в Кардиологии. 2022. Т. 18, № 5. С. 530–535. EDN: HUFTZE doi: 10.20996/1819-6446-2022-09-01

25. Бочкарева Е.В., Бутина Е.К., Байрамкулова Н.Х., Драпкина О.М. Кальциноз артерий молочной железы и сахарный диабет: клинический пример и краткий обзор литературы // Профилактическая медицина. 2021. Т. 24, № 9. С. 97–101. EDN: QPQDLT doi: 10.17116/profmed20212409197
26. Бочкарева Е.В., Бутина Е.К., Савин А.С., и др. Кальциноз артерий молочной железы: потенциальный суррогатный маркер цереброваскулярных заболеваний // Профилактическая медицина. 2020. Т. 23, № 5. С. 164–169. EDN: IRHLDZ doi: 10.17116/profmed202023051164
27. Бочкарева Е.В., Бутина Е.К., Савин А.С., Драпкина О.М. Кальциноз артерий молочной железы и остеопороз у женщины в постменопаузе (клинический случай и мнение по проблеме) // Кардиоваскулярная терапия и профилактика. 2020. Т. 19, № 4. С. 2574. EDN: RTDDQG doi: 10.15829/1728-8800-2020-2574
28. Wang J., Ding H., Bidgoli F.A., et al. Detecting Cardiovascular Disease from Mammograms With Deep Learning // IEEE Trans Med Imaging. 2017. Vol. 36, N 5. P. 1172–1181. doi: 10.1109/TMI.2017.2655486
29. Голубев Н.А., Огрызко Е.В., Тюрина Е.М., Шелепова Е.А., Шелехов П.В. Особенности развития службы лучевой диагностики в Российской Федерации за 2014–2019 года // Современные проблемы здравоохранения и медицинской статистики. 2021. № 2. С. 356–376. EDN: EHSADW doi: 10.24412/2312-2935-2021-2-356-376
30. Krupinski E.A., Berbaum K.S., Caldwell R.T., et al. Long radiology workdays reduce detection and accommodation accuracy // J Am Coll Radiol. 2010. Vol. 7, N 9. P. 698–704. doi: 10.1016/j.jacr.2010.03.004
31. Lee C.S., Nagy P.G., Weaver S.J., Newman-Toker D.E. Cognitive and system factors contributing to diagnostic errors in radiology // AJR Am J Roentgenol. 2013. Vol. 201, N 3. P. 611–617. doi: 10.2214/AJR.12.10375
32. Николаев А.Е., Шапиев А.Н., Блохин И.А., и др. Новые подходы к оценке изменений коронарных артерий при мульти-спиральной компьютерной томографии // Российский кардиологический журнал. 2019. № 12. С. 124–130. EDN: VHYAYK doi: 10.15829/1560-4071-2019-12-124-130
33. Guo X., O'Neill W.C., Vey B., et al. SCU-Net: A deep learning method for segmentation and quantification of breast arterial calcifications on mammograms // Med Phys. 2021. Vol. 48, N 10. P. 5851–5861. doi: 10.1002/mp.15017
34. Yacoub B., Kabakus I.M., Schoepf U.J., et al. Performance of an Artificial Intelligence-Based Platform Against Clinical Radiology Reports for the Evaluation of Noncontrast Chest CT // Acad Radiol. 2022. Vol. 29, N 2. P. 108–117. doi: 10.1016/j.acra.2021.02.007
35. Isgum I., Rutten A., Prokop M., van Ginneken B. Detection of coronary calcifications from computed tomography scans for automated risk assessment of coronary artery disease // Med Phys. 2007. Vol. 34, N 4. P. 1450–1461. doi: 10.1118/1.2710548
36. Kurkure U., Chittajallu D.R., Brunner G., et al. A supervised classification-based method for coronary calcium detection in non-contrast CT // Int J Cardiovasc Imaging. 2010. Vol. 26, N 7. P. 817–828. doi: 10.1007/s10554-010-9607-2
37. Brunner G., Chittajallu D.R., Kurkure U., Kakadiaris I.A. Toward the automatic detection of coronary artery calcification in non-contrast computed tomography data // Int J Cardiovasc Imaging. 2010. Vol. 26, N 7. P. 829–838. doi: 10.1007/s10554-010-9608-1
38. Brunner G., Kurkure U., Chittajallu D.R., et al. Toward unsupervised classification of calcified arterial lesions // Med Image Comput Comput Assist Interv. 2008. Vol. 11, N 1. P. 144–152. doi: 10.1007/978-3-540-85988-8_18
39. Takx R.A., de Jong P.A., Leiner T., et al. Automated coronary artery calcification scoring in non-gated chest CT: agreement and reliability // PLoS One. 2014. Vol. 9, N 3. P. e91239. doi: 10.1371/journal.pone.0091239
40. Wolterink J.M., Leiner T., Takx R.A., et al. Automatic Coronary Calcium Scoring in Non-Contrast-Enhanced ECG-Triggered Cardiac CT With Ambiguity Detection // IEEE Trans Med Imaging. 2015. Vol. 34, N 9. P. 1867–1878. doi: 10.1109/TMI.2015.2412651
41. Saur S.C., Alkadhi H., Desbiolles L., et al. Automatic detection of calcified coronary plaques in computed tomography data sets // Med Image Comput Comput Assist Interv. 2008. Vol. 11, N 1. P. 170–177. doi: 10.1007/978-3-540-85988-8_21
42. Yang G., Chen Y., Ning X., et al. Automatic coronary calcium scoring using noncontrast and contrast CT images // Med Phys. 2016. Vol. 43, N 5. P. 2174. doi: 10.1118/1.4945045
43. Jiang B., Guo N., Ge Y., et al. Development and application of artificial intelligence in cardiac imaging // Br J Radiol. 2020. Vol. 93, N 1113. P. 20190812. doi: 10.1259/bjr.20190812
44. Shahzad R., van Walsum T., Schaap M., et al. Vessel specific coronary artery calcium scoring: an automatic system // Acad Radiol. 2013. Vol. 20, N 1. P. 1–9. doi: 10.1016/j.acra.2012.07.018
45. Cano-Espinosa C., González G., Washko G.R., et al. Automated Agatston Score Computation in non-ECG Gated CT Scans Using Deep Learning // Proc SPIE Int Soc Opt Eng. 2018. Vol. 10574. P. 105742K. doi: 10.1117/12.2293681
46. Gogin N., Viti M., Nicodème L., et al. Automatic coronary artery calcium scoring from unenhanced-ECG-gated CT using deep learning // Diagn Interv Imaging. 2021. Vol. 102, N 11. P. 683–690. doi: 10.1016/j.diii.2021.05.004
47. Wolterink J.M., Leiner T., de Vos B.D., et al. Automatic coronary artery calcium scoring in cardiac CT angiography using paired convolutional neural networks // Med Image Anal. 2016. Vol. 34. P. 123–136. doi: 10.1016/j.media.2016.04.004
48. Wang W., Wang H., Chen Q., et al. Coronary artery calcium score quantification using a deep-learning algorithm // Clin Radiol. 2020. Vol. 75, N 3. P. 237.e11–237.e16. doi: 10.1016/j.crad.2019.10.012
49. Singh G., Al'Aref S.J., Lee B.C., et al. End-to-End, Pixel-Wise Vessel-Specific Coronary and Aortic Calcium Detection and Scoring Using Deep Learning // Diagnostics (Basel). 2021. Vol. 11, N 2. P. 215. doi: 10.3390/diagnostics11020215
50. Martin S.S., van Assen M., Rapaka S., et al. Evaluation of a Deep Learning-Based Automated CT Coronary Artery Calcium Scoring Algorithm // JACC Cardiovasc Imaging. 2020. Vol. 13, N 1. P. 524–526. doi: 10.1016/j.jcmg.2019.09.015
51. Zhang N., Yang G., Zhang W., et al. Fully automatic framework for comprehensive coronary artery calcium scores analysis on non-contrast cardiac-gated CT scan: Total and vessel-specific quantifications // Eur J Radiol. 2021. Vol. 134. P. 109420. doi: 10.1016/j.ejrad.2020.109420
52. de Vos B.D., Wolterink J.M., Leiner T., et al. Direct Automatic Coronary Calcium Scoring in Cardiac and Chest CT // IEEE Trans Med Imaging. 2019. Vol. 38, N 9. P. 2127–2138. doi: 10.1109/TMI.2019.2899534
53. AlGhamdi M., Abdel-Mottaleb M., Collado-Mesa F. DU-Net: Convolutional Network for the Detection of Arterial Calcifications in Mammograms // IEEE Trans Med Imaging. 2020. Vol. 39, N 10. P. 3240–3249. doi: 10.1109/TMI.2020.2989737

54. Николаев А.Е., Коркунова О.А., Хуторной И.В., и др. Сопоставимость методик оценки коронарных рисков по данным ультра-НДКТ грудной клетки и КТ-коронарографии с ЭКГ-синхронизацией // Медицинская визуализация. 2021. Т. 25, № 4. С. 75–92. EDN: CMSGAX doi: 10.24835/1607-0763-1047
55. van Assen M., Martin S.S., Varga-Szemes A., et al. Automatic coronary calcium scoring in chest CT using a deep neural network in direct comparison with non-contrast cardiac CT: A validation study // *Eur J Radiol.* 2021. Vol. 134. P. 109428. doi: 10.1016/j.ejrad.2020.109428
56. Николаев А.Е., Шапиев А.Н., Блохин И.А. Стандартизация оценки кальцификации коронарных артерий на бесконтрастных компьютерных томограммах без ЭКГ-синхронизации // *Radiology Study.* 2020. Т. 3, № 2. С. 45–52. EDN: VVGXBI
57. Isgum I., Prokop M., Niemeijer M., et al. Automatic coronary calcium scoring in low-dose chest computed tomography // *IEEE Trans Med Imaging.* 2012. Vol. 31, N 12. P. 2322–2334. doi: 10.1109/TMI.2012.2216889
58. Wolterink J.M., Leiner T., Viergever M.A., Isgum I. Generative Adversarial Networks for Noise Reduction in Low-Dose CT // *IEEE Trans Med Imaging.* 2017. Vol. 36, N 12. P. 2536–2545. doi: 10.1109/TMI.2017.2708987
59. Klug M., Shemesh J., Green M., et al. A deep-learning method for the denoising of ultra-low dose chest CT in coronary artery calcium score evaluation // *Clin Radiol.* 2022. Vol. 77, N 7. P. 509–517. doi: 10.1016/j.crad.2022.03.005
60. Sun Z., Ng C.K.C. Artificial Intelligence (Enhanced Super-Resolution Generative Adversarial Network) for Calcium Deblooming in Coronary Computed Tomography Angiography: A Feasibility Study // *Diagnostics (Basel).* 2022. Vol. 12, N 4. P. 991. doi: 10.3390/diagnostics12040991
61. Eng D., Chute C., Khandwala N., et al. Automated coronary calcium scoring using deep learning with multicenter external validation // *NPJ Digit Med.* 2021. Vol. 4, N 1. P. 88. doi: 10.1038/s41746-021-00460-1
62. Морозов С.П., Кокина Д.Ю., Павлов Н.А., и др. Клинические аспекты применения искусственного интеллекта для интерпретации рентгенограмм органов грудной клетки // *Туберкулез и болезни легких.* 2021. Т. 99, № 4. С. 58–64. doi: 10.21292/2075-1230-2021-99-4-58-64
63. Kamel P.I., Yi P.H., Sair H.I., Lin C.T. Prediction of Coronary Artery Calcium and Cardiovascular Risk on Chest Radiographs Using Deep Learning // *Radiol Cardiothorac Imaging.* 2021. Vol. 3, N 3. P. e200486. doi: 10.1148/ryct.2021200486
64. Du T., Xie L., Zhang H., et al. Training and validation of a deep learning architecture for the automatic analysis of coronary angiography // *EuroIntervention.* 2021. Vol. 17, N 1. P. 32–40. doi: 10.4244/EIJ-D-20-00570
65. Isgum I., Rutten A., Prokop M., et al. Automated aortic calcium scoring on low-dose chest computed tomography // *Med Phys.* 2010. Vol. 37, N 2. P. 714–723. doi: 10.1118/1.3284211
66. de Vos B.D., Lessmann N., de Jong P.A., Işgum I. Deep Learning-Quantified Calcium Scores for Automatic Cardiovascular Mortality Prediction at Lung Screening Low-Dose CT // *Radiol Cardiothorac Imaging.* 2021. Vol. 3, N 2. P. e190219. doi: 10.1148/ryct.2021190219
67. van Velzen S.G.M., Lessmann N., Velthuis B.K., et al. Deep Learning for Automatic Calcium Scoring in CT: Validation Using Multiple Cardiac CT and Chest CT Protocols // *Radiology.* 2020. Vol. 295, N 1. P. 66–79. doi: 10.1148/radiol.2020191621
68. Guilelea F.N., Casciaro M.E., Pascaner A.F., et al. Thoracic Aorta Calcium Detection and Quantification Using Convolutional Neural Networks in a Large Cohort of Intermediate-Risk Patients // *Tomography.* 2021. Vol. 7, N 4. P. 636–649. doi: 10.3390/tomography7040054
69. Reid S., Schousboe J.T., Kimelman D., et al. Machine learning for automated abdominal aortic calcification scoring of DXA vertebral fracture assessment images: A pilot study // *Bone.* 2021. Vol. 148. P. 115943. doi: 10.1016/j.bone.2021.115943
70. Graffy P.M., Liu J., O'Connor S., et al. Automated segmentation and quantification of aortic calcification at abdominal CT: application of a deep learning-based algorithm to a longitudinal screening cohort // *Abdom Radiol (NY).* 2019. Vol. 44, N 8. P. 2921–2928. doi: 10.1007/s00261-019-02014-2
71. van Engelen A., Niessen W.J., Klein S., et al. Atherosclerotic plaque component segmentation in combined carotid MRI and CTA data incorporating class label uncertainty // *PLoS One.* 2014. Vol. 9, N 4. P. e94840. doi: 10.1371/journal.pone.0094840
72. Онищенко П.С., Клышников К.Ю., Овчаренко Е.А. Искусственные нейронные сети в кардиологии: анализ графических данных // *Бюллетень сибирской медицины.* 2021. Т. 20, № 4. С. 193–204. EDN: XVBERA doi: 10.20538/1682-0363-2021-4-193-204
73. Bortsova G., Bos D., Dubost F., et al. Automated Segmentation and Volume Measurement of Intracranial Internal Carotid Artery Calcification at Noncontrast CT // *Radiol Artif Intell.* 2021. Vol. 3, N 5. P. e200226. doi: 10.1148/ryai.2021200226
74. Li D., Qiao H., Han Y., et al. Histological validation of simultaneous non-contrast angiography and intraplaque hemorrhage imaging (SNAP) for characterizing carotid intraplaque hemorrhage // *Eur Radiol.* 2021. Vol. 31, N 5. P. 3106–3115. doi: 10.1007/s00330-020-07352-0
75. Chen S., Ning J., Zhao X., et al. Fast simultaneous noncontrast angiography and intraplaque hemorrhage (fSNAP) sequence for carotid artery imaging // *Magn Reson Med.* 2017. Vol. 77, N 2. P. 753–758. doi: 10.1002/mrm.26111
76. Qi H., Sun J., Qiao H., et al. Carotid Intraplaque Hemorrhage Imaging with Quantitative Vessel Wall T1 Mapping: Technical Development and Initial Experience // *Radiology.* 2018. Vol. 287, N 1. P. 276–284. doi: 10.1148/radiol.2017170526
77. Cheng J.Z., Cole E.B., Pisano E.D., Shen D. Detection of arterial calcification in mammograms by random walks // *Inf Process Med Imaging.* 2009. Vol. 21. P. 713–724. doi: 10.1007/978-3-642-02498-6_59
78. Ломаков С.Ю. Объёмы маммографических исследований в современных условиях проведения профилактических мероприятий // *Профилактическая медицина.* 2020. Т. 23, № 4. С. 41–44. EDN: OUUINQ doi: 10.17116/profmed20202304141
79. Roseman D.A., Hwang S.J., Manders E.S., et al. Renal artery calcium, cardiovascular risk factors, and indexes of renal function // *Am J Cardiol.* 2014. Vol. 113, N 1. P. 156–161. doi: 10.1016/j.amjcard.2013.09.036

REFERENCES

- Sharapova OV, Kicha DI, Gerasimova LI, et al. Map analysis of morbidity and mortality from blood circulatory system diseases of the population of the Russian federation (2010–2019). *Complex Issues of Cardiovascular Diseases*. 2022;11(1):56–68. EDN: ZUQVNA doi: 10.17802/2306-1278-2022-11-1-56-68
- Mal'kov OA, Govorukhina AA, Burykin YuG, Afineevskaya AYU. The Role of Calcification in the Pathogenesis of Inflammatory Reaction in the Arterial Wall (Exemplified by the Vessels of the Neck and Head in Adults). *Journal of Medical and Biological Research*. 2021;9(4):435–443. EDN: FTSKDS doi: 10.37482/2687-1491-2081
- Archakova TV, Nedosugova LV. Factors of vascular calcification in patients with type 2 diabetes mellitus on long-term dialysis. *Diabetes mellitus*. 2020;23(2):125–131. EDN: KPXIVL doi: 10.14341/DM10145
- Mori H, Torii S, Kutyna M, et al. Coronary Artery Calcification and its Progression: What Does it Really Mean? *JACC Cardiovasc Imaging*. 2018;11(1):127–142. doi: 10.1016/j.jcmg.2017.10.012
- Yeo KK. Artificial intelligence in cardiology: did it take off? *Russian Journal for Personalized Medicine*. 2022;2(6):16–22. EDN: UIENOT doi: 10.18705/2782-3806-2022-2-6-16-22
- Karpov OE, Andrikov DA, Maksimenko VA, Hramov AE. Explainable artificial intelligence for medicine. *Medical Doctor and IT*. 2022;2(2):4–11. EDN: DTCAXW doi: 10.25881/18110193_2022_2_4
- Greenland P, LaBree L, Azen SP, et al. Coronary artery calcium score combined with Framingham score for risk prediction in asymptomatic individuals. *JAMA*. 2004;291(2):210–215. doi: 10.1001/jama.291.2.210
- Criqui MH, Denenberg JO, Ix JH, et al. Calcium density of coronary artery plaque and risk of incident cardiovascular events. *JAMA*. 2014;311(3):271–278. doi: 10.1001/jama.2013.282535
- Carr JJ, Jacobs DR Jr, Terry JG, et al. Association of Coronary Artery Calcium in Adults Aged 32 to 46 Years With Incident Coronary Heart Disease and Death. *JAMA Cardiol*. 2017;2(4):391–399. doi: 10.1001/jamacardio.2016.5493
- Khalikov AA, Kuznetsov KO, Iskuzhina LR, Khalikova LV. Forensic aspects of sudden autopsy-negative cardiac death. *Sudebno-Meditsinskaya Ekspertisa*. 2021;64(3):59–63. doi: 10.17116/sudmed20216403159
- Eisen A, Tenenbaum A, Koren-Morag N, et al. Calcification of the thoracic aorta as detected by spiral computed tomography among stable angina pectoris patients: association with cardiovascular events and death. *Circulation*. 2008;118(13):1328–1334. doi: 10.1161/CIRCULATIONAHA.107.712141
- Itani Y, Watanabe S, Masuda Y. Relationship between aortic calcification and stroke in a mass screening program using a mobile helical computed tomography unit. *Circ J*. 2006;70(6):733–736. doi: 10.1253/circj.70.733
- Lee R, Matsutani N, Polimenakos AC, et al. Preoperative noncontrast chest computed tomography identifies potential aortic emboli. *Ann Thorac Surg*. 2007;84(1):38–42. doi: 10.1016/j.athoracsur.2007.03.025
- Zweig BM, Sheth M, Simpson S, Al-Mallah MH. Association of abdominal aortic calcium with coronary artery calcium and obstructive coronary artery disease: a pilot study. *Int J Cardiovasc Imaging*. 2012;28(2):399–404. doi: 10.1007/s10554-011-9818-1
- An C, Lee HJ, Lee HS, et al. CT-based abdominal aortic calcification score as a surrogate marker for predicting the presence of asymptomatic coronary artery disease. *Eur Radiol*. 2014;24(10):2491–2498. doi: 10.1007/s00330-014-3298-3
- Melnikov MV, Zelinskiy VA, Zhorina AS, Chuglova DA. An abdominal aortic calcification in peripheral arterial occlusive disease: risk factors and markers. *Journal of atherosclerosis and dyslipidemias*. 2014;3(3):33–38. EDN: SISNRZ
- Bagger YZ, Tankó LB, Alexandersen P, et al. Radiographic measure of aorta calcification is a site-specific predictor of bone loss and fracture risk at the hip. *J Intern Med*. 2006;259(6):598–605. doi: 10.1111/j.1365-2796.2006.01640.x
- Zsulc P, Blackwell T, Schousboe JT, et al. High hip fracture risk in men with severe aortic calcification: MrOS study. *J Bone Miner Res*. 2014;29(4):968–975. doi: 10.1002/jbmr.2085
- Lobanova NI, Chicherina EN, Malchikova SV, Maksimchuk-Kolobova NS. Fluid shear stress on the endothelium of the carotid artery wall and coronary artery calcinosis in patients with arterial hypertension. *South Russian Journal of Therapeutic Practice*. 2022;3(3):60–67. EDN: QWCOCH doi: 10.21886/2712-8156-2022-3-3-60-67
- Kim JT, Yoo SH, Kwon JH, et al. Subtyping of ischemic stroke based on vascular imaging: analysis of 1,167 acute, consecutive patients. *J Clin Neurol*. 2006;2(4):225–230. doi: 10.3988/jcn.2006.2.4.225
- Wong LK. Global burden of intracranial atherosclerosis. *Int J Stroke*. 2006;1(3):158–159. doi: 10.1111/j.1747-4949.2006.00045.x
- Kockelkoren R, De Vis JB, de Jong PA, et al. Intracranial Carotid Artery Calcification From Infancy to Old Age. *J Am Coll Cardiol*. 2018;72(5):582–584. doi: 10.1016/j.jacc.2018.05.021
- Huang Z, Xiao J, Xie Y, et al. The correlation of deep learning-based CAD-RADS evaluated by coronary computed tomography angiography with breast arterial calcification on mammography. *Sci Rep*. 2020;10(1):11532. doi: 10.1038/s41598-020-68378-4
- Bochkareva EV, Butina EK, Bayramkulova EK, et al. Prevalence and Severity of Breast Arterial Calcification on Routine Mammography. *Rational Pharmacotherapy in Cardiology*. 2022;18(5):530–535. EDN: HUFTZE doi: 10.20996/1819-6446-2022-09-01
- Bochkareva EV, Butina EK, Bayramkulova NK, Drapkina OM. Mammary artery calcinosis and diabetes mellitus: case report and brief literature review. *Profilakticheskaya Meditsina*. 2021;24(9):97–101. EDN: QPQDLT doi: 10.17116/profmed20212409197
- Bochkareva EV, Butina EK, Savin AS, et al. Breast arteries calcification: a potential surrogate marker for cerebrovascular disease. *Profilakticheskaya Meditsina*. 2020;23(5):164–169. EDN: IRHLDZ doi: 10.17116/profmed202023051164
- Bochkareva EV, Butina EK, Savin AS, Drapkina OM. Breast artery calcification and osteoporosis in postmenopausal woman: a case report and opinion on the problem. *Cardiovascular Therapy and Prevention*. 2020;19(4):2574. EDN: RTDDQG doi: 10.15829/1728-8800-2020-2574
- Wang J, Ding H, Bidgoli FA, et al. Detecting Cardiovascular Disease from Mammograms With Deep Learning. *IEEE Trans Med Imaging*. 2017;36(5):1172–1181. doi: 10.1109/TMI.2017.2655486
- Golubev NA, Ogryzko EV, Tyurina EM, Shelepova EA, Shelekhov PV. Features of the development of the radiation diagnostics service in the Russian Federation for 2014–2019. *Current problems of health care and medical statistics*. 2021;2(2):356–376. EDN: EHSADW doi: 10.24412/2312-2935-2021-2-356-376

30. Krupinski EA, Berbaum KS, Caldwell RT, et al. Long radiology workdays reduce detection and accommodation accuracy. *J Am Coll Radiol*. 2010;7(9):698–704. doi: 10.1016/j.jacr.2010.03.004
31. Lee CS, Nagy PG, Weaver SJ, Newman-Toker DE. Cognitive and system factors contributing to diagnostic errors in radiology. *AJR Am J Roentgenol*. 2013;201(3):611–617. doi: 10.2214/AJR.12.10375
32. Nikolaev AE, Shapiev AN, Blokhin IA, et al. New approaches for assessing coronary changes in multi-layer spiral computed tomography. *Russian Journal of Cardiology*. 2019;(12):124–130. EDN: VHYAYK doi: 10.15829/1560-4071-2019-12-124-130
33. Guo X, O'Neill WC, Vey B, et al. SCU-Net: A deep learning method for segmentation and quantification of breast arterial calcifications on mammograms. *Med Phys*. 2021;48(10):5851–5861. doi: 10.1002/mp.15017
34. Yacoub B, Kabakus IM, Schoepf UJ, et al. Performance of an Artificial Intelligence-Based Platform Against Clinical Radiology Reports for the Evaluation of Noncontrast Chest CT. *Acad Radiol*. 2022;29(2):108–117. doi: 10.1016/j.acra.2021.02.007
35. Isgum I, Rutten A, Prokop M, van Ginneken B. Detection of coronary calcifications from computed tomography scans for automated risk assessment of coronary artery disease. *Med Phys*. 2007;34(4):1450–1461. doi: 10.1118/1.2710548
36. Kurkure U, Chittajallu DR, Brunner G, et al. A supervised classification-based method for coronary calcium detection in non-contrast CT. *Int J Cardiovasc Imaging*. 2010;26(7):817–828. doi: 10.1007/s10554-010-9607-2
37. Brunner G, Chittajallu DR, Kurkure U, Kakadiaris IA. Toward the automatic detection of coronary artery calcification in non-contrast computed tomography data. *Int J Cardiovasc Imaging*. 2010;26(7):829–838. doi: 10.1007/s10554-010-9608-1
38. Brunner G, Kurkure U, Chittajallu DR, et al. Toward unsupervised classification of calcified arterial lesions. *Med Image Comput Comput Assist Interv*. 2008;11(1):144–152. doi: 10.1007/978-3-540-85988-8_18
39. Takx RA, de Jong PA, Leiner T, et al. Automated coronary artery calcification scoring in non-gated chest CT: agreement and reliability. *PLoS One*. 2014;9(3):e91239. doi: 10.1371/journal.pone.0091239
40. Wolterink JM, Leiner T, Takx RA, et al. Automatic Coronary Calcium Scoring in Non-Contrast-Enhanced ECG-Triggered Cardiac CT With Ambiguity Detection. *IEEE Trans Med Imaging*. 2015;34(9):1867–1878. doi: 10.1109/TMI.2015.2412651
41. Saur SC, Alkadi H, Desbiolles L, et al. Automatic detection of calcified coronary plaques in computed tomography data sets. *Med Image Comput Comput Assist Interv*. 2008;11(1):170–177. doi: 10.1007/978-3-540-85988-8_21
42. Yang G, Chen Y, Ning X, et al. Automatic coronary calcium scoring using noncontrast and contrast CT images. *Med Phys*. 2016;43(5):2174. doi: 10.1118/1.4945045
43. Jiang B, Guo N, Ge Y, et al. Development and application of artificial intelligence in cardiac imaging. *Br J Radiol*. 2020;93(1113):20190812. doi: 10.1259/bjr.20190812
44. Shahzad R, van Walsum T, Schaap M, et al. Vessel specific coronary artery calcium scoring: an automatic system. *Acad Radiol*. 2013;20(1):1–9. doi: 10.1016/j.acra.2012.07.018
45. Cano-Espinosa C, González G, Washko GR, et al. Automated Agatston Score Computation in non-ECG Gated CT Scans Using Deep Learning. *Proc SPIE Int Soc Opt Eng*. 2018;10574:105742K. doi: 10.1117/12.2293681
46. Gogin N, Viti M, Nicodème L, et al. Automatic coronary artery calcium scoring from unenhanced-ECG-gated CT using deep learning. *Diagn Interv Imaging*. 2021;102(11):683–690. doi: 10.1016/j.diii.2021.05.004
47. Wolterink JM, Leiner T, de Vos BD, et al. Automatic coronary artery calcium scoring in cardiac CT angiography using paired convolutional neural networks. *Med Image Anal*. 2016;34:123–136. doi: 10.1016/j.media.2016.04.004
48. Wang W, Wang H, Chen Q, et al. Coronary artery calcium score quantification using a deep-learning algorithm. *Clin Radiol*. 2020;75(3):237.e11–237.e16. doi: 10.1016/j.crad.2019.10.012
49. Singh G, Al'Aref SJ, Lee BC, et al. End-to-End, Pixel-Wise Vessel-Specific Coronary and Aortic Calcium Detection and Scoring Using Deep Learning. *Diagnostics (Basel)*. 2021;11(2):215. doi: 10.3390/diagnostics11020215
50. Martin SS, van Assen M, Rapaka S, et al. Evaluation of a Deep Learning-Based Automated CT Coronary Artery Calcium Scoring Algorithm. *JACC Cardiovasc Imaging*. 2020;13(1):524–526. doi: 10.1016/j.jcmg.2019.09.015
51. Zhang N, Yang G, Zhang W, et al. Fully automatic framework for comprehensive coronary artery calcium scores analysis on non-contrast cardiac-gated CT scan: Total and vessel-specific quantifications. *Eur J Radiol*. 2021;134:109420. doi: 10.1016/j.ejrad.2020.109420
52. de Vos BD, Wolterink JM, Leiner T, et al. Direct Automatic Coronary Calcium Scoring in Cardiac and Chest CT. *IEEE Trans Med Imaging*. 2019;38(9):2127–2138. doi: 10.1109/TMI.2019.2899534
53. AlGhamdi M, Abdel-Mottaleb M, Collado-Mesa F. DU-Net: Convolutional Network for the Detection of Arterial Calcifications in Mammograms. *IEEE Trans Med Imaging*. 2020;39(10):3240–3249. doi: 10.1109/TMI.2020.2989737
54. Nikolaev AE, Korkunova OA, Khutorov IV, et al. Comparability of coronary risk assessment methods with chest ultra-LDCT and CT coronography with ECG synchronization. *Medical Visualization*. 2021;25(4):75–92. EDN: CMSGAX doi: 10.24835/1607-0763-1047
55. van Assen M, Martin SS, Varga-Szemes A, et al. Automatic coronary calcium scoring in chest CT using a deep neural network in direct comparison with non-contrast cardiac CT: A validation study. *Eur J Radiol*. 2021;134:109428. doi: 10.1016/j.ejrad.2020.109428
56. Nikolaev AE, Shapiev AN, Blokhin IA. Standardization of coronary artery calcification assessment on contrast-free computed tomograms without ECG synchronization. *Radiology Study*. 2020;3(2):45–52. EDN: VVGXBI
57. Isgum I, Prokop M, Niemeijer M, et al. Automatic coronary calcium scoring in low-dose chest computed tomography. *IEEE Trans Med Imaging*. 2012;31(12):2322–2334. doi: 10.1109/TMI.2012.2216889
58. Wolterink JM, Leiner T, Viergever MA, Isgum I. Generative Adversarial Networks for Noise Reduction in Low-Dose CT. *IEEE Trans Med Imaging*. 2017;36(12):2536–2545. doi: 10.1109/TMI.2017.2708987
59. Klug M, Shemesh J, Green M, et al. A deep-learning method for the denoising of ultra-low dose chest CT in coronary artery calcium score evaluation. *Clin Radiol*. 2022;77(7):509–517. doi: 10.1016/j.crad.2022.03.005
60. Sun Z, Ng KKC. Artificial Intelligence (Enhanced Super-Resolution Generative Adversarial Network) for Calcium Deblooming in Coronary Computed Tomography Angiography: A Feasibility Study. *Diagnostics (Basel)*. 2022;12(4):991. doi: 10.3390/diagnostics12040991

61. Eng D, Chute C, Khandwala N, et al. Automated coronary calcium scoring using deep learning with multicenter external validation. *NPJ Digit Med*. 2021;4(1):88. doi: 10.1038/s41746-021-00460-1
62. Morozov SP, Kokina DYU, Pavlov NA, et al. Clinical aspects of using artificial intelligence for the interpretation of chest X-rays. *Tuberculosis and Lung Diseases*. 2021;99(4):58–64. doi: 10.21292/2075-1230-2021-99-4-58-64
63. Kamel PI, Yi PH, Sair HI, Lin CT. Prediction of Coronary Artery Calcium and Cardiovascular Risk on Chest Radiographs Using Deep Learning. *Radiol Cardiothorac Imaging*. 2021;3(3):e200486. doi: 10.1148/ryct.2021200486
64. Du T, Xie L, Zhang H, et al. Training and validation of a deep learning architecture for the automatic analysis of coronary angiography. *EuroIntervention*. 2021;17(1):32–40. doi: 10.4244/EIJ-D-20-00570
65. Isgum I, Rutten A, Prokop M, et al. Automated aortic calcium scoring on low-dose chest computed tomography. *Med Phys*. 2010;37(2):714–723. doi: 10.1118/1.3284211
66. de Vos BD, Lessmann N, de Jong PA, Işgum I. Deep Learning-Quantified Calcium Scores for Automatic Cardiovascular Mortality Prediction at Lung Screening Low-Dose CT. *Radiol Cardiothorac Imaging*. 2021;3(2):e190219. doi: 10.1148/ryct.2021190219
67. van Velzen SGM, Lessmann N, Velthuis BK, et al. Deep Learning for Automatic Calcium Scoring in CT: Validation Using Multiple Cardiac CT and Chest CT Protocols. *Radiology*. 2020;295(1):66–79. doi: 10.1148/radiol.2020191621
68. Guilenea FN, Casciaro ME, Pascaner AF, et al. Thoracic Aorta Calcium Detection and Quantification Using Convolutional Neural Networks in a Large Cohort of Intermediate-Risk Patients. *Tomography*. 2021;7(4):636–649. doi: 10.3390/tomography7040054
69. Reid S, Schousboe JT, Kimelman D, et al. Machine learning for automated abdominal aortic calcification scoring of DXA vertebral fracture assessment images: A pilot study. *Bone*. 2021;148:115943. doi: 10.1016/j.bone.2021.115943
70. Graffy PM, Liu J, O'Connor S, et al. Automated segmentation and quantification of aortic calcification at abdominal CT: application of a deep learning-based algorithm to a longitudinal screening cohort. *Abdom Radiol (NY)*. 2019;44(8):2921–2928. doi: 10.1007/s00261-019-02014-2
71. van Engelen A, Niessen WJ, Klein S, et al. Atherosclerotic plaque component segmentation in combined carotid MRI and CTA data incorporating class label uncertainty. *PLoS One*. 2014;9(4):e94840. doi: 10.1371/journal.pone.0094840
72. Onishchenko PS, Klyshnikov KYu, Ovcharenko EA. Artificial neural networks in cardiology: analysis of graphic data. *Bulletin of Siberian Medicine*. 2021;20(4):193–204. EDN: XVBERA doi: 10.20538/1682-0363-2021-4-193-204
73. Bortsova G, Bos D, Dubost F, et al. Automated Segmentation and Volume Measurement of Intracranial Internal Carotid Artery Calcification at Noncontrast CT. *Radiol Artif Intell*. 2021;3(5):e200226. doi: 10.1148/ryai.2021200226
74. Li D, Qiao H, Han Y, et al. Histological validation of simultaneous non-contrast angiography and intraplaque hemorrhage imaging (SNAP) for characterizing carotid intraplaque hemorrhage. *Eur Radiol*. 2021;31(5):3106–3115. doi: 10.1007/s00330-020-07352-0
75. Chen S, Ning J, Zhao X, et al. Fast simultaneous noncontrast angiography and intraplaque hemorrhage (fSNAP) sequence for carotid artery imaging. *Magn Reson Med*. 2017;77(2):753–758. doi: 10.1002/mrm.26111
76. Qi H, Sun J, Qiao H, et al. Carotid Intraplaque Hemorrhage Imaging with Quantitative Vessel Wall T1 Mapping: Technical Development and Initial Experience. *Radiology*. 2018;287(1):276–284. doi: 10.1148/radiol.2017170526
77. Cheng JZ, Cole EB, Pisano ED, Shen D. Detection of arterial calcification in mammograms by random walks. *Inf Process Med Imaging*. 2009;21:713–724. doi: 10.1007/978-3-642-02498-6_59
78. Lomakov SYu. Volumes of mammographic studies in modern conditions of providing preventive measures. *Profilakticheskaya Meditsina*. 2020;23(4):41–44. EDN: OUUINQ doi: 10.17116/profmed20202304141
79. Roseman DA, Hwang SJ, Manders ES, et al. Renal artery calcium, cardiovascular risk factors, and indexes of renal function. *Am J Cardiol*. 2014;113(1):156–161. doi: 10.1016/j.amjcard.2013.09.036

ОБ АВТОРАХ

* Нуркаева Адилья Салаватовна;

адрес: Россия 450008, Уфа, ул. ул. Заки Валиди, 45а;

ORCID: 0009-0006-8621-5580;

eLibrary SPIN: 3307-5546;

e-mail: vkomissiya@inbox.ru

Трусов Юрий Александрович;

ORCID: 0000-0001-6407-3880;

eLibrary SPIN: 3203-5314;

e-mail: yu.a.trusov@samsmu.ru

Чупахина Виктория Сергеевна;

ORCID: 0009-0003-8318-3673;

eLibrary SPIN: 4402-7476;

e-mail: chupalhina@bk.ru

Яковенко Наталья Александровна;

ORCID: 0009-0005-6726-9623;

eLibrary SPIN: 4415-2236;

e-mail: tigris2011@yandex.ru

AUTHORS' INFO

* Adilya S. Nurkaeva;

address: 45a Zaki Validi str. 450008, Ufa, Russia;

ORCID: 0009-0006-8621-5580;

eLibrary SPIN: 3307-5546;

e-mail: vkomissiya@inbox.ru

Yuri A. Trusov;

ORCID: 0000-0001-6407-3880;

eLibrary SPIN: 3203-5314;

e-mail: yu.a.trusov@samsmu.ru

Victoria S. Chupakhina;

ORCID: 0009-0003-8318-3673;

eLibrary SPIN: 4402-7476;

e-mail: chupalhina@bk.ru

Natalia A. Yakovenko;

ORCID: 0009-0005-6726-9623;

eLibrary SPIN: 4415-2236;

e-mail: tigris2011@yandex.ru

* Автор, ответственный за переписку / Corresponding author

Абленина Ирина Витальевна;

ORCID: 0009-0006-6222-9339;

eLibrary SPIN: 4123-3336;

e-mail: aninelba@gmail.com

Латыпова Роксана Фанилевна;

ORCID: 0009-0004-5057-6451;

eLibrary SPIN: 3542-3376;

e-mail: roxevanssss@gmail.com

Питке Александра Петровна;

ORCID: 0009-0002-1111-759X;

eLibrary SPIN: 3726-4213;

e-mail: pitkea00@gmail.com

Язовских Анастасия Алексеевна;

ORCID: 0000-0002-3955-0830;

eLibrary SPIN: 3543-5323;

e-mail: anyaz.bgmu@yandex.ru

Иванов Артём Сергеевич;

ORCID: 0009-0000-3562-8293;

eLibrary SPIN: 4834-5324;

e-mail: artem.ivanov656@yandex.ru

Богатырева Дарья Сергеевна;

ORCID: 0009-0004-5055-8819;

eLibrary SPIN: 3331-3421;

e-mail: diria1012@yandex.ru

Попова Ульяна Андреевна;

ORCID: 0009-0002-7994-5631;

eLibrary SPIN: 3452-2543;

e-mail: ulyanka.popova.2000@gmail.com

Юзлекбав Азат Флюрович;

ORCID: 0009-0002-8799-4732;

eLibrary SPIN: 4812-3213;

e-mail: ztl5@rambler.ru

Irina V. Ablenina;

ORCID: 0009-0006-6222-9339;

eLibrary SPIN: 4123-3336;

e-mail: aninelba@gmail.com

Roksana F. Latypova;

ORCID: 0009-0004-5057-6451;

eLibrary SPIN: 3542-3376;

e-mail: roxevanssss@gmail.com

Aleksandra P. Pitke;

ORCID: 0009-0002-1111-759X;

eLibrary SPIN: 3726-4213;

e-mail: pitkea00@gmail.com

Anastasiya A. Yazovskih;

ORCID: 0000-0002-3955-0830;

eLibrary SPIN: 3543-5323;

e-mail: anyaz.bgmu@yandex.ru

Artem S. Ivanov;

ORCID: 0009-0000-3562-8293;

eLibrary SPIN: 4834-5324;

e-mail: artem.ivanov656@yandex.ru

Darya S. Bogatyreva;

ORCID: 0009-0004-5055-8819;

eLibrary SPIN: 3331-3421;

e-mail: diria1012@yandex.ru

Ulyana A. Popova;

ORCID: 0009-0002-7994-5631;

eLibrary SPIN: 3452-2543;

e-mail: ulyanka.popova.2000@gmail.com

Azat F. Yuzlekbaev;

ORCID: 0009-0002-8799-4732;

eLibrary SPIN: 4812-3213;

e-mail: ztl5@rambler.ru

DOI: <https://doi.org/10.17816/DD515814>

Перспективы применения компьютерного зрения для выявления камней в мочевыделительной системе и новообразований печени и почек на изображениях компьютерной томографии органов брюшной полости и забрюшинного пространства

Ю.А. Васильев^{1,2}, А.В. Владзимирский^{1,3}, К.М. Арзамасов¹, Д.У. Шихмурадов¹,
А.В. Панкратов¹, И.В. Ульянов¹, Н.Б. Нечаев¹

¹ Научно-практический клинический центр диагностики и телемедицинских технологий, Москва, Россия;

² Национальный медико-хирургический Центр имени Н.И. Пирогова, Москва, Россия;

³ Первый Московский государственный медицинский университет имени И.М. Сеченова, Москва, Россия

АННОТАЦИЯ

В работе представлен селективный обзор литературы, посвящённый использованию алгоритмов компьютерного зрения для диагностики новообразований печени и почек, а также камней в мочевыделительной системе на изображениях компьютерной томографии органов брюшной полости и забрюшинного пространства.

В обзор были включены статьи, опубликованные за период с 01.01.2020 по 24.04.2023 гг.

В задаче сегментации печени и её новообразований алгоритмы, оперирующие пикселями, показали наибольшие значения параметров диагностической точности (точность достигает 99,6%; коэффициент сходства Дайса — 0,99). Задачи классификации новообразований печени на текущий момент лучше решаются воксельными алгоритмами (точность до 82,5%).

Сегментация почек и их новообразований, а также классификация опухолей почек одинаково хорошо выполняются алгоритмами, анализирующими как пиксели, так и воксели (точность достигает 99,3%, коэффициент сходства Дайса — 0,97).

Алгоритмы компьютерного зрения в настоящее время также способны с высокой степенью точности определять конкременты в мочевыделительной системе размерами от 3 мм (точность достигает 93,0%).

Таким образом, существующие алгоритмы компьютерного зрения позволяют не только эффективно выявлять новообразования печени и почек, а также конкременты в мочевыделительной системе, но и с высокой точностью определять их количественные и качественные характеристики.

Более высокая точность определения вида новообразования может быть достигнута за счёт оценки воксельных данных, поскольку в этом случае алгоритм анализирует новообразование полностью в трёх измерениях, а не только в плоскости одного среза.

Ключевые слова: компьютерная томография; нейронные сети; глубокое машинное обучение; органы брюшной полости; мочекаменная болезнь; образования почек; образования печени.

Как цитировать:

Васильев Ю.А., Владзимирский А.В., Арзамасов К.М., Шихмурадов Д.У., Панкратов А.В., Ульянов И.В., Нечаев Н.Б. Перспективы применения компьютерного зрения для выявления камней в мочевыделительной системе и новообразований печени и почек на изображениях компьютерной томографии органов брюшной полости и забрюшинного пространства // Digital Diagnostics. 2024. Т. 5, № 1. С. 101–119. DOI: <https://doi.org/10.17816/DD515814>

DOI: <https://doi.org/10.17816/DD515814>

Prospects of using computer vision technology to detect urinary stones and liver and kidney neoplasms on computed tomography images of the abdomen and retroperitoneal space

Yuriy A. Vasilev^{1,2}, Anton V. Vladzmyrskyy^{1,3}, Kirill M. Arzamasov¹, David U. Shikhmuradov¹, Andrey V. Pankratov¹, Iliya V. Ulyanov¹, Nikolay B. Nechaev¹

¹ Research and Practical Clinical Center for Diagnostics and Telemedicine Technologies, Moscow, Russia;

² National Medical and Surgical Center Named after N.I. Pirogov, Moscow, Russia;

³ I.M. Sechenov First Moscow State Medical University, Moscow, Russia

ABSTRACT

The article presents a selective literature review on the use of computer vision algorithms for the diagnosis of liver and kidney neoplasms and urinary stones using computed tomography images of the abdomen and retroperitoneal space. The review included articles published between January 1, 2020, and April 24, 2023. Pixel-based algorithms showed the greatest diagnostic accuracy parameters for segmenting the liver and its neoplasms (accuracy, 99.6%; Dice similarity coefficient, 0.99). Voxel-based algorithms were superior at classifying liver neoplasms (accuracy, 82.5%). Pixel- and voxel-based algorithms fared equally well in segmenting kidneys and their neoplasms, as well as classifying kidney tumors (accuracy, 99.3%; Dice similarity coefficient, 0.97). Computer vision algorithms can detect urinary stones measuring 3 mm or larger with a high degree of accuracy of up to 93.0%. Thus, existing computer vision algorithms not only effectively detect liver and kidney neoplasms and urinary stones but also accurately determine their quantitative and qualitative characteristics. Evaluating voxel data improves the accuracy of neoplasm type determination since the algorithm analyzes the neoplasm in three dimensions rather than only the plane of one slice.

Keywords: computed tomography; neural networks; deep learning; abdomen; urolithiasis; renal neoplasms; liver neoplasms.

To cite this article:

Vasilev YuA, Vladzmyrskyy AV, Arzamasov KM, Shikhmuradov DU, Pankratov AV, Ulyanov IV, Nechaev NB. Prospects of using computer vision technology to detect urinary stones and liver and kidney neoplasms on computed tomography images of the abdomen and retroperitoneal space. *Digital Diagnostics*. 2024;5(1):101–119. DOI: <https://doi.org/10.17816/DD515814>

DOI: <https://doi.org/10.17816/DD515814>

计算机视觉在腹部和腹膜后计算机断层扫描图片上检测泌尿系统结石和肝肾肿块的应用前景

Yuriy A. Vasilev^{1,2}, Anton V. Vladzmyrskyy^{1,3}, Kirill M. Arzamasov¹, David U. Shikhmuradov¹, Andrey V. Pankratov¹, Iliya V. Ulyanov¹, Nikolay B. Nechaev¹

¹ Research and Practical Clinical Center for Diagnostics and Telemedicine Technologies, Moscow, Russia;

² National Medical and Surgical Center Named after N.I. Pirogov, Moscow, Russia;

³ I.M. Sechenov First Moscow State Medical University, Moscow, Russia

摘要

本文对计算机视觉算法在腹部和腹膜后计算机断层扫描图片被用于诊断肝肾肿块以及泌尿系统结石的情况进行了有选择性的文献综述。

综述中的文章发表于2020年1月1日至2023年4月24日。

在肝脏及其肿块的分割任务中，使用像素算法显示出最高的诊断准确率参数值（准确率达到99.6%；Dice相似系数为0.99）。目前，基于体素的算法能较好地解决肝肿块分类任务（准确率高达82.5%）。

通过分析像素和体素的算法，肾脏及其肿块的分割和肾肿块的分类同样出色（准确率达到99.3%，Dice相似系数为0.97）。

现在，计算机视觉算法也能高度准确地检测出泌尿系统中3毫米及以上大小的结石（准确率达到93.0%）。

因此，现有的计算机视觉算法不仅能有效检测肝肾肿块以及泌尿系统中的结石，还能高度准确地确定它们的定量和定性特征。

通过评估体素数据，可以提高肿块类检测的准确度。在这种情况下，算法会对整个肿块进行三维分析，而不仅只是在一个切片的平面上进行分析。

关键词：电子计算机断层扫描；神经网络；深度机器学习；腹部器官；泌尿系结石病；肾肿块；肝肿块。

引用本文：

Vasilev YuA, Vladzmyrskyy AV, Arzamasov KM, Shikhmuradov DU, Pankratov AV, Ulyanov IV, Nechaev NB. 计算机视觉在腹部和腹膜后计算机断层扫描图片上检测泌尿系统结石和肝肾肿块的应用前景. *Digital Diagnostics*. 2024;5(1):101–119. DOI: <https://doi.org/10.17816/DD515814>

收到: 27.06.2023

接受: 22.12.2023

发布日期: 11.03.2024

ВВЕДЕНИЕ

За последние несколько лет лучевая диагностика претерпела ряд существенных изменений. В частности, началось активное использование технологий, основанных на компьютерном зрении, при интерпретации изображений компьютерной томографии (КТ) с целью улучшения и ускорения диагностики заболеваний, а также снижения нагрузки на медицинский персонал [1–3]. Ряд алгоритмов искусственного интеллекта, анализирующих КТ-изображения органов грудной клетки, уже продемонстрировали высокие показатели точности по отдельным нозологиям (площадь под ROC-кривой достигла 0,88) [3].

Активно развивается компьютерное зрение и в диагностике патологии органов брюшной полости. Количество работ, посвящённых данному вопросу, которые были опубликованы на ресурсе PubMed, выросло в 12 раз за последние пять лет (с 34 в 2018 г. до 411 в 2022 г.). Бурный рост количества научных исследований может быть обусловлен увеличением доступности КТ для населения, достаточно большим и пополняющимся перечнем выявляемых заболеваний, а также высокой точностью их верификации с помощью КТ.

На текущий момент уже доступны готовые решения, основанные на технологиях компьютерного зрения, которые способны обнаруживать такие распространённые патологии, как новообразования печени и почек, а также конкременты в мочевыделительной системе на КТ органов брюшной полости и забрюшинного пространства [4].

В основе таких решений лежат алгоритмы, которые по своей функции делятся на два вида:

1. выделяющие (сегментирующие) органы и их патологию;
2. классифицирующие патологию.

В то же время описываемые решения демонстрируют разный уровень диагностической точности, что в определённой мере может быть обусловлено архитектурой, лежащей в основе сетей глубокого обучения и алгоритмов компьютерного зрения. Наибольшую популярность в области классификации на текущий момент имеют архитектуры глубокого машинного обучения, основанные на свёрточных нейронных сетях [5].

Настоящий обзор посвящён изучению диагностической точности алгоритмов компьютерного зрения, предназначенных для обнаружения новообразований печени и почек, конкрементов в мочевыделительной системе на КТ-изображениях, в зависимости от назначения данных алгоритмов (сегментация или классификация), а также архитектуры, лежащей в их основе.

МЕТОДИКА ПОИСКА

Проведено аналитическое исследование: селективный обзор литературы, фокусом которого являлись алгоритмы, предназначенные для первичной диагностики и работающие с такими распространёнными заболеваниями,

как новообразования печени и почек, а также мочекаменная болезнь.

Несмотря на то, что довольно распространёнными являются также и некоторые другие опухоли (например, опухоли поджелудочной железы), которые могут быть выявлены на КТ органов брюшной полости и забрюшинного пространства, в настоящем обзоре внимание авторов было сфокусировано исключительно на новообразованиях печени, почек и конкрементах в мочевыводящей системе. Работ, посвящённых использованию компьютерного зрения для обнаружения опухолей других органов данных анатомических областей, существенно меньше, или такие работы отсутствуют.

Поиск научных публикаций осуществлялся с помощью интернет-сервиса PubMed (доступ от 31.04.2023) по комбинациям ключевых слов: ["Deep Learning", "Neural Network", "Artificial intelligence"] + ["Liver tumor", "Kidney tumor", "Hepatocellular carcinoma", "Kidney Stone"] + "Computed Tomography".

Кроме того, был произведён поиск в электронной библиотеке научных публикаций и национальной информационно-аналитической системе Российского индекса научного цитирования eLibrary (доступ от 31.04.2023) по ключевым словам «Искусственный интеллект» + «компьютерная томография» за период с 2019 года по настоящее время, однако работ, посвящённых непосредственно алгоритмам глубокого обучения для диагностики патологии органов брюшной полости и забрюшинного пространства, не найдено.

Из исследований, найденных с помощью интернет-сервиса PubMed, в анализ включены работы, в которых алгоритмы компьютерного зрения использовались для сегментации и классификации целевой патологии на КТ-снимках органов брюшной полости и забрюшинного пространства, была описана архитектура алгоритма глубокого обучения и представлен результат работы алгоритма с помощью одного из показателей: коэффициента сходства Дайса в задачах сегментации и точности, F1-меры или площади под ROC кривой (AUC) в задачах классификации [6].

Глубина поиска ограничивалась периодом с 01.01.2020 по 24.04.2023.

РЕЗУЛЬТАТЫ

Таким образом, в обзор включена 21 работа, данные из которых представлены в Приложении 1. В отобранных работах был произведён анализ представленной архитектуры, а также оценены диагностические метрики. Произведено сопоставление с другими публичными работами, не попавшими в анализ.

Новообразования печени

Наиболее информативными методами диагностики новообразований печени на сегодняшний день являются

КТ с контрастным усилением, а также магнитно-резонансная томография [7]. При этом КТ по сравнению с магнитно-резонансной томографией имеет ряд преимуществ, таких как распространённость оборудования, подготовленность специалистов, скорость исследования и экономическая эффективность [8]. Использование контрастного усиления является стандартным подходом при подозрении на новообразование печени ввиду малой информативности бесконтрастных исследований. Тем не менее при ряде других заболеваний большое количество КТ-исследований органов брюшной полости выполняется без контраста. Способность алгоритмов компьютерного зрения определять новообразования печени и на нативных КТ-изображениях могла бы использоваться для скрининга данной патологии [9–11].

В задачах сегментации печени и её новообразований наиболее часто используется архитектура U-Net и её модификации (в частности использование блоков ResNet), показывающие достаточно высокую диагностическую точность. Наибольшие показатели в задаче сегментации печени и её опухолей были получены в работе Н. Rahman и соавт. при использовании ResUNet: коэффициент сходства Дайса составил 0,99, точность — 99,6% [12]. Пример сегментации новообразования печени представлен на рис. 1.

Алгоритмы, оперирующие пикселями (двухмерными изображениями) для сегментации, показали лучшие диагностические метрики в сравнении с алгоритмами, использующими воксели (трёхмерные изображения) [12–18].

В задачах по классификации образований печени можно отметить, что диагностические показатели лучше у воксельных алгоритмов. При этом уже сейчас можно

увидеть, что данные алгоритмы с высокой степенью достоверности позволяют классифицировать образования на доброкачественные и злокачественные (точность достигает 82,5%). Точность определения конкретного вида злокачественных опухолей в настоящий момент является более низкой и достигает лишь 73,4% [19, 20].

Несмотря на развитие и повсеместное использование глубокого машинного обучения, стоит отметить, что некоторые классические алгоритмы машинного обучения (например, support vector machine — SVM) также показывают высокие диагностические метрики при классификации опухолей печени: точность достигает 84,6% [19, 21].

Сегодня на базе Государственного бюджетного учреждения здравоохранения города Москвы «Научно-практический клинический центр диагностики и телемедицинских технологий Департамента здравоохранения города Москвы» проводится работа по созданию алгоритма компьютерного зрения для сегментации и дифференцировки патологических образований печени внутри классов с использованием контрастного усиления. Пример работы представлен на рис. 2.

Новообразования почек

В 27–50% случаев объёмные образования почек протекают бессимптомно и выявляются случайно [22]. КТ позволяет не только определить локализацию и размеры опухоли, но и оценить её взаимоотношение с почечной лоханкой и крупными сосудами.

Наиболее часто для решения задачи сегментации почек и их новообразований в проанализированных работах используется архитектура U-Net и её модификации. На текущий момент коэффициент сходства Дайса при сегментации




Рис. 1. Пример сегментации новообразования печени, выполненной одним из алгоритмов.




Рис. 2. Пример сегментации новообразования печени, выполненной алгоритмом на изображении компьютерной томографии с контрастным усилением.

почек достигает 0,97 при использовании архитектуры 3D U-Net [23]. С помощью этой же архитектуры был получен наибольший коэффициент сходства Дайса в задаче сегментации опухолей почек (0,84) и кист почек (0,54). Таким образом, точность сегментации новообразований почек пока уступает точности сегментации самих почек.

Кроме того, важно отметить, что показатели диагностической точности при сегментации почки и её новообразований на КТ-срезах у архитектур, оперирующих

вокселями, оказались не хуже, чем у классических алгоритмов, оперирующих пикселями [23–26].

Другие архитектуры (например, EffectiveNet) также демонстрируют высокие значения коэффициента сходства Дайса при сегментации почек и их новообразований (до 0,95) [27, 28]. Пример сегментации новообразований почек представлен на рис. 3.

Для решения задач классификации новообразований почек используются как классические алгоритмы




Рис. 3. Пример сегментации новообразования правой почки.

машинного обучения, так и алгоритмы, основанные на глубоком машинном обучении [24, 26, 29–31]. Наибольшую точность (99,3%) показывают архитектуры Swin Transformers [29].

В условиях ограниченности данных хорошо проявляют себя классические алгоритмы машинного обучения и архитектуры прямого распространения [26]. Так же, как и в задаче сегментации почек и их опухолей, при решении задачи классификации архитектуры, использующие воксели, не уступают по точности архитектурам, использующим пиксели [31].

Мочекаменная болезнь

Мочекаменная болезнь находится на втором месте по выявляемости среди урологических заболеваний [32]. При этом заболеваемость мочекаменной болезнью и её распространённость среди взрослого населения неуклонно растут во всех регионах Российской Федерации. Согласно исследованию Н. Гаджиева и соавт., распространённость мочекаменной болезни увеличилась на 35,4% за 15-летний период, а заболеваемость выросла на 16,2% [33].

В диагностике мочекаменной болезни КТ забрюшинного пространства является золотым стандартом, позволяющим определить локализацию, форму, размеры и количество рентген-контрастных конкрементов с чувствительностью до 96% и специфичностью до 100% [34].

В проанализированных статьях отмечается прямая зависимость точности определения конкрементов от их размера. С увеличением размера конкрементов уровень точности для алгоритмов, основанных на свёрточных нейронных сетях, растёт [35, 36]. Так, камни размером менее 1 см обнаруживаются с точностью 85%, размером

от 1 до 2 см — с точностью 89%, размером более 2 см — с точностью 93%.

Наиболее высокую точность определения конкрементов в мочевыводящей системе на сегодняшний день продемонстрировал алгоритм на основе трансформеров (Swin Transformers) — 98% [29]. Пример обнаружения конкремента одним из алгоритмов представлен на рис. 4.

Сложности в использовании алгоритмов компьютерного зрения для диагностики мочекаменной болезни при выявлении мелких конкрементов могут возникать при наличии мелких атеросклеротических бляшек в стенках почечных артерий, плотность которых соответствует уратным конкрементам [36].

При этом современные технологии в области глубокого машинного обучения и компьютерного зрения позволяют при низкой лучевой нагрузке определять конкременты размерами от 3 мм, тогда как клинически значимыми считаются конкременты размером от 5 мм [37].

Определение типа конкремента — один из наиболее важных факторов, влияющих на последующую лечебную тактику [35, 37]. В работах, посвящённых определению прогноза послеоперационного периода (в частности, безрецидивного течения), а также определению типа конкремента на основе технологий машинного обучения, используется множество различных характеристик, определяемых на основе КТ [38–41]. Ряд работ по использованию двухэнергетической КТ (Dual-Energy CT, DECT) показывает возможность использования данного метода визуализации для определения в том числе и химического состава конкремента [42, 43], однако этот метод имеет ряд ограничений, в первую очередь он малоприменим в рутинной практике [44].




Рис. 4. Пример обнаружения конкремента одним из алгоритмов.

Y. Cui и соавт. показали, что при использовании узкоспециализированных свёрточных нейронных сетей можно проводить оценку камней по шкале нефролитометрии S.T.O.N.E. с результатами, сопоставимыми с заключениями врачей-рентгенологов [45]. Такой подход позволяет также оценивать прогностический фактор для пациентов [46].

ОБСУЖДЕНИЕ

В ряде работ исследования проводились на публичных наборах данных, таких как LiTS, KiTS'19, 3D-IRCADb и других, которые содержат в себе преимущественно контрастные исследования. В работах, где использовались собственные КТ-изображения, наборы данных в основном также состояли из контрастных исследований или включали в себя смешанные данные.

Согласно проанализированным публикациям, современное развитие алгоритмов глубокого машинного обучения позволяет с высокой степенью точности проводить сегментацию печени (максимальный коэффициент сходства Дайса — 0,99, средний — $0,92 \pm 0,09$), а также сегментацию почек (максимальный коэффициент сходства Дайса — 0,97, средний — $0,94 \pm 0,02$) на КТ-изображениях (см. Приложение 1).

В задаче сегментации печени наибольшие значения показателей диагностической точности демонстрируются алгоритмами, оперирующими пикселями (максимальный коэффициент сходства Дайса — 0,99, средний — $0,97 \pm 0,01$), тогда как в задаче сегментации почек воксельные алгоритмы не уступают пиксельным. Возможно, это обусловлено разными размерами и разной плотностью данных паренхиматозных органов, а также историческими особенностями развития алгоритмов. Использование вокселей требует большей производительности, подобные вычислительные системы в широком доступе стали появляться относительно недавно, и в настоящее время они получают большую базу усовершенствованных, основанных на пикселях алгоритмов, которые также продолжают развиваться в исследовательских центрах.

Точность сегментации новообразований печени и почек ниже точности сегментации самих этих органов. Неточность сегментации новообразований обусловлена преимущественно неполнотой их сегментации. Правильное определение границ новообразований зависит от типа их роста и структуры, поэтому экзофитные гетерогенные образования сегментируются лучше всего [23]. С этим же связана и низкая точность сегментации простых изоденсных кист, гемангиом и т.д. [20].

Использование предобработки данных перед проведением их через сегментирующий алгоритм позволяет частично решить данную проблему [27, 28]. K. Yildirim и соавт. показали, что анализ альтернативных срезов КТ, таких как сагиттальный или коронарный, алгоритмами

глубокого машинного обучения также позволяет повысить точность обнаружения патологии [47].

Согласно проанализированной литературе, для целей классификации новообразований более обосновано использование вокселей, чем пикселей, так как по типу строения опухоли можно определить её природу [19, 26, 31]. Технологии, основанные на глубоком обучении, позволяют с высокой точностью классифицировать новообразования органов брюшной полости на доброкачественные и злокачественные [19, 20, 31].

Полнота сегментации имеет большое значение для корректности последующей классификации. В настоящее время можно использовать комбинацию 2D-алгоритмов для сегментации и 3D-алгоритмов — для классификации [19, 24]. Кроме того, использование комбинации алгоритмов глубокого машинного обучения в сочетании с алгоритмами классического машинного обучения (в том числе градиентный бустинг) может позволить улучшить диагностические метрики [19]. В проанализированных работах можно выделить два варианта комбинации этих алгоритмов. L. Yang и соавт., а также M. Shehata и соавт. предлагают формировать признаки алгоритмическими методами и использовать их в сети прямого распространения [30, 31]. E. Trivizakis и соавт., а также X.L. Zhu и соавт., наоборот, формируют признаки из сетей глубокого обучения и классифицируют их на алгоритмах классического машинного обучения [19, 26].

Не менее важным аспектом является внедрение архитектуры трансформера для классификации новообразований, но её использование лимитировано количеством данных для обучения. Для получения высоких метрик при использовании архитектур на основе трансформеров требуется в разы больше данных для обучения, чем для свёрточных нейронных сетей [29].

В проанализированных работах используются стандартные метрики оценки качества алгоритмов глубокого машинного обучения, но методология проведения исследований отличалась от работы к работе, что затрудняет адекватную сравнительную оценку диагностической точности. Дополнительным ограничением является непредоставление большинством авторов 95% доверительного интервала полученных значений параметров диагностической точности, что не позволяет оценить достоверность различий метрик, полученных при использовании различных архитектур нейронных сетей и подходов. Внедрение методологии стандартизированной оценки может быть полезным для определения алгоритмов с лучшими результатами [48]. Дополнительно необходимо отметить ограниченность выборок в некоторых рассмотренных нами исследованиях.

Другим направлением использования алгоритмов глубокого машинного обучения является улучшение качества КТ-изображений, полученных при низкодозовых исследованиях. Например, F.R. Schwartz и соавт. предлагают использовать алгоритмы глубокого машинного обучения

для интерполяции и реконструкции данных при использовании двухэнергетической КТ [49–51]. Благодаря такому подходу можно получать высокоэнергетические изображения при низкой дозе лучевой нагрузки.

Таким образом, в настоящее время алгоритмы компьютерного зрения уже демонстрируют высокие параметры диагностической точности при выявлении камней в мочевыделительной системе и новообразований печени и почек на КТ-изображениях. Следующая задача — это интеграция компьютерного зрения в работу медицинских организаций для улучшения и ускорения диагностики заболеваний, а также снижения нагрузки на медицинский персонал. Необходимы дальнейшие более масштабные, проспективные и тщательные исследования, оценивающие эффективность применения программного обеспечения на основе технологий искусственного интеллекта для поиска новообразований органов брюшной полости в рамках скрининга, а также их качественная и количественная оценка с последующей верификацией результатов.

ЗАКЛЮЧЕНИЕ

Существующие системы компьютерного зрения для оценки КТ органов брюшной полости и забрюшинного пространства позволяют не только эффективно выявлять новообразования печени и почек, а также конкременты в мочевыделительной системе, но и с высокой точностью определять их количественные и качественные характеристики. Дальнейшее техническое развитие приведёт к эволюции 3D-алгоритмов глубокого обучения и улучшению их диагностической точности, что в свою очередь позволит получать более достоверные результаты, особенно в задачах мультиклассовой классификации. Более высокая точность определения вида патологии может быть достигнута за счёт использования воксельных данных, потому что в этом случае алгоритм может анализировать образование полностью в трёх измерениях, а не только в плоскости одного среза.

Более глубокая оценка полученных в результате работы компьютерного зрения данных может быть использована в дальнейшем для определения «ценности» фаз контрастного исследования. Развитие методов улучшения качества получаемых КТ-изображений позволит выполнять сканирование только в определённые фазы (например, в артериальную и экскреторную) в зависимости от конкретных целей, что приведёт к снижению получаемой пациентом эффективной дозы облучения.

СПИСОК ЛИТЕРАТУРЫ

1. Ильяшенко О.Ю., Лукьянченко Е.Л. Возможности применения компьютерного зрения для анализа данных в медицине // Известия Саратовско-

ДОПОЛНИТЕЛЬНАЯ ИНФОРМАЦИЯ

Источник финансирования. Данная статья подготовлена авторским коллективом в рамках научно-исследовательской работы «Научные методологии устойчивого развития технологий искусственного интеллекта в медицинской диагностике» (номер в Единой государственной информационной системе учёта: № 123031500004-5) в соответствии с Приказом от 21.12.2022 № 1196 «Об утверждении государственных заданий, финансовое обеспечение которых осуществляется за счёт средств бюджета города Москвы государственным бюджетным (автономным) учреждениям подведомственным Департаменту здравоохранения города Москвы, на 2023 год и плановый период 2024 и 2025 годов» Департамента здравоохранения города Москвы.

Конфликт интересов. Авторы декларируют отсутствие явных и потенциальных конфликтов интересов, связанных с публикацией настоящей статьи.

Вклад авторов. Все авторы подтверждают соответствие своего авторства международным критериям ICMJE (все авторы внесли существенный вклад в разработку концепции, проведение исследования и подготовку статьи, прочли и одобрили финальную версию перед публикацией).

Наибольший вклад распределён следующим образом: Ю.А. Васильев, А.В. Владимирский, К.М. Арзамасов — концепция исследования; Н.Б. Нечаев — написание текста статьи; Д.У. Шихмуратов, А.В. Панкратов, И.В. Ульянов — анализ данных.

ADDITIONAL INFORMATION

Funding source. This article was prepared by a group of authors as a part of the research and development effort titled “Evidence-based methodologies for sustainable development of artificial intelligence in medical imaging” (USIS No. 123031500004-5) in accordance with the Order No. 1196 dated December 21, 2022 “On approval of state assignments funded by means of allocations from the budget of the city of Moscow to the state budgetary (autonomous) institutions subordinate to the Moscow Health Care Department, for 2023 and the planned period of 2024 and 2025” issued by the Moscow Health Care Department.

Competing interests. The authors declare that they have no competing interests.

Authors' contribution. All authors made a substantial contribution to the conception of the work, acquisition, analysis, interpretation of data for the work, drafting and revising the work, final approval of the version to be published and agree to be accountable for all aspects of the work. Yu.A. Vasiliev, A.V. Vladimirovsky, K.M. Arzamasov — research concept; N.B. Nechaev — writing the text of the article; D.W. Shikhmuratov, A.V. Pankratov, I.V. Ulyanov — data analysis.

го университета. Новая серия. Серия : Математика. Механика. Информатика. 2022. Т. 22, № 2. С. 224–232. EDN: MCSLQK doi: 10.18500/1816-9791-2022-22-2-224-232

2. Алексеева М.Г., Зубов А.И., Новиков М.Ю. Искусственный интеллект в медицине // Международный научно-исследовательский журнал. 2022. Т. 7, № 121. С. 10–13. EDN: JMMMDf doi: 10.23670/IRJ.2022.121.7.038
3. Гусев А.В., Владимирский А.В., Шарова Д.Е., Арзамасов К.М., Храмов А.Е. Развитие исследований и разработок в сфере технологий искусственного интеллекта для здравоохранения в Российской Федерации: итоги 2021 года // Digital Diagnostics. 2022. Т. 3, № 3. С. 178–194. EDN: KHWQWZ doi: 10.17816/DD107367
4. Wang L., Wang H., Huang Y., et al. Trends in the application of deep learning networks in medical image analysis: Evolution between 2012 and 2020 // Eur J Radiol. 2022. Vol. 146. P. 110069. doi: 10.1016/j.ejrad.2021.110069
5. Alrefai N., Ibrahim O. Al Deep learning-based cancer classification for microarray data: A systematic review // Journal of Theoretical and Applied Information Technology. 2021. Vol. 99. P. 2312–2332. doi: 10.5281/zenodo.6126510
6. Клинические испытания систем искусственного интеллекта (лучевая диагностика) / под ред. Ю.А. Васильева, А.В. Владимирского, Д.Е. Шаровой, и др. Москва : ГБУЗ «НПКЦ ДиТ ДЗМ», 2023. EDN: PUJLD
7. Lee J., Kim K.W., Kim S.Y., et al. Automatic detection method of hepatocellular carcinomas using the non-rigid registration method of multi-phase liver CT images // J Xray Sci Technol. 2015. Vol. 23, N 3. P. 275–288. doi: 10.3233/XST-150487
8. Patel B.N., Boltynkov A.T., Martinez M.G., et al. Cost-effectiveness of dual-energy CT versus multiphasic single-energy CT and MRI for characterization of incidental indeterminate renal lesions // Abdom Radiol (NY). 2020. Vol. 45, N 6. P. 1896–1906. doi: 10.1007/s00261-019-02380-x
9. Marrero J.A., Kulik L.M., Sirlin C.B., et al. Diagnosis, Staging, and Management of Hepatocellular Carcinoma: 2018 Practice Guidance by the American Association for the Study of Liver Diseases // Hepatology. 2018. Vol. 68, N 2. P. 723–750. doi: 10.1002/hep.29913
10. Ayuso C., Rimola J., Vilana R., et al. Diagnosis and staging of hepatocellular carcinoma (HCC): current guidelines // Eur J Radiol. 2018. Vol. 101. P. 72–81. doi: 10.1016/j.ejrad.2018.01.025
11. Клинические рекомендации — Рак печени (гепатоцеллюлярный). ID 1. Одобрено Научно-практическим Советом Минздрава РФ. 2022. Режим доступа: https://cr.minzdrav.gov.ru/schema/1_3 Дата обращения: 03.04.2023
12. Rahman H., Bukht T.F.N., Imran A., et al. A Deep Learning Approach for Liver and Tumor Segmentation in CT Images Using ResUNet // Bioengineering (Basel). 2022. Vol. 9, N 8. P. 368. doi: 10.3390/bioengineering9080368
13. Maqsood M., Bukhari M., Ali Z., et al. A Residual-Learning-Based Multi-Scale Parallel-Convolutions-Assisted Efficient CAD System for Liver Tumor Detection // Mathematics. 2021. Vol. 9, N 10. P. 1133. doi: 10.3390/math9101133
14. Khan R.A., Luo Y., Wu F.X. RMS-UNet: Residual multi-scale UNet for liver and lesion segmentation // Artif Intell Med. 2022. Vol. 124. P. 102231. doi: 10.1016/j.artmed.2021.102231
15. Affane A., Kucharski A., Chapuis P., et al. Segmentation of Liver Anatomy by Combining 3D U-Net Approaches // Applied Sciences. 2021. Vol. 11, N 11. P. 4895. doi: 10.3390/app11114895
16. Han X., Wu X., Wang S., et al. Automated segmentation of liver segment on portal venous phase MR images using a 3D convolutional neural network // Insights Imaging. 2022. Vol. 13, N 1. P. 26. doi: 10.1186/s13244-022-01163-1
17. Wang J., Zhang X., Guo L., et al. Multi-scale attention and deep supervision-based 3D UNet for automatic liver segmentation from CT // Math Biosci Eng. 2023. Vol. 20, N 1. P. 1297–1316. doi: 10.3934/mbe.2023059
18. Kashala K.G., Song Y., Liu Z. Optimization of FireNet for Liver Lesion Classification // Electronics. 2020. Vol. 9, N 8. P. 1237. doi: 10.3390/electronics9081237
19. Trivizakis E., Manikis G.C., Nikiforaki K., et al. Extending 2-D Convolutional Neural Networks to 3-D for Advancing Deep Learning Cancer Classification With Application to MRI Liver Tumor Differentiation // IEEE J Biomed Health Inform. 2019. Vol. 23, N 3. P. 923–930. doi: 10.1109/JBHI.2018.2886276
20. Zhou J., Wang W., Lei B., et al. Automatic Detection and Classification of Focal Liver Lesions Based on Deep Convolutional Neural Networks: A Preliminary Study // Front Oncol. 2021. Vol. 10. P. 581210. doi: 10.3389/fonc.2020.581210
21. Rela M., Rao S.N., Patil R.R. Performance analysis of liver tumor classification using machine learning algorithms // International Journal of Advanced Technology and Engineering Exploration. 2022. Vol. 9, N 86. P. 143–154. doi: 10.19101/IJATEE.2021.87465
22. Oberai A., Varghese B., Cen S., et al. Deep learning based classification of solid lipid-poor contrast enhancing renal masses using contrast enhanced CT // Br J Radiol. 2020. Vol. 93, N 1111. P. 20200002. doi: 10.1259/bjr.20200002
23. Lin Z., Cui Y., Liu J., et al. Automated segmentation of kidney and renal mass and automated detection of renal mass in CT urography using 3D U-Net-based deep convolutional neural network // Eur Radiol. 2021. Vol. 31, N 7. P. 5021–5031. doi: 10.1007/s00330-020-07608-9
24. Toda N., Hashimoto M., Arita Y., et al. Deep Learning Algorithm for Fully Automated Detection of Small (≤ 4 cm) Renal Cell Carcinoma in Contrast-Enhanced Computed Tomography Using a Multicenter Database // Invest Radiol. 2022. Vol. 57, N 5. P. 327–333. doi: 10.1097/RLI.0000000000000842
25. Ding Y., Chen Z., Wang Z., et al. Three-dimensional deep neural network for automatic delineation of cervical cancer in planning computed tomography images // J Appl Clin Med Phys. 2022. Vol. 23, N 4. P. e13566. doi: 10.1002/acm2.13566
26. Zhu X.L., Shen H.B., Sun H., et al. Improving segmentation and classification of renal tumors in small sample 3D CT images using transfer learning with convolutional neural networks // Int J Comput Assist Radiol Surg. 2022. Vol. 17, N 7. P. 1303–1311. doi: 10.1007/s11548-022-02587-2
27. Hsiao C.H., Sun T.L., Lin P.C., et al. A deep learning-based precision volume calculation approach for kidney and tumor segmentation on computed tomography images // Comput

- Methods Programs Biomed. 2022. Vol. 221. P. 106861. doi: 10.1016/j.cmpb.2022.106861
- 28.** Hsiao C.H., Lin P.C., Chung L.A., et al. A deep learning-based precision and automatic kidney segmentation system using efficient feature pyramid networks in computed tomography images // *Comput Methods Programs Biomed.* 2022. Vol. 221. P. 106854. doi: 10.1016/j.cmpb.2022.106854
- 29.** Islam M.N., Hasan M., Hossain M.K., et al. Vision transformer and explainable transfer learning models for auto detection of kidney cyst, stone and tumor from CT-radiography // *Sci Rep.* 2022. Vol. 12, N 1. P. 11440. doi: 10.1038/s41598-022-15634-4
- 30.** Yang L., Gao L., Arefan D., et al. A CT-based radiomics model for predicting renal capsule invasion in renal cell carcinoma // *BMC Med Imaging.* 2022. Vol. 22, N 1. P. 15. doi: 10.1186/s12880-022-00741-5
- 31.** Shehata M., Alksas A., Abouelkheir R.T., et al. A Comprehensive Computer-Assisted Diagnosis System for Early Assessment of Renal Cancer Tumors // *Sensors (Basel).* 2021. Vol. 21, N 14. P. 4928. doi: 10.3390/s21144928
- 32.** Куликовский В.Ф., Шкодкин С.В., Батищев С.А., и др. Современные представления о эпидемиологии и патогенезе уролитиаза // *Научный результат. Медицина и фармация.* 2016. Т. 2, № 4. С. 4–12. EDN: NSGAXL doi: 10.18413/2313-8955-2016-2-4-4-12
- 33.** Gadzhiev N., Prosyannikov M., Malkhasyan V., et al. Urolithiasis prevalence in the Russian Federation: analysis of trends over a 15-year period // *World J Urol.* 2021. Vol. 39, N 10. P. 3939–3944. doi: 10.1007/s00345-021-03729-y
- 34.** Урология. Российские клинические рекомендации / под ред. Ю.Г. Аляева, П.В. Глыбочко, Д.Ю. Пушкаря. Москва : ГЭОТАРМедиа, 2016.
- 35.** Caglayan A., Horsanali M.O., Kocadurdu K., et al. Deep learning model-assisted detection of kidney stones on computed tomography // *Int Braz J Urol.* 2022. Vol. 48, N 5. P. 830–839. doi: 10.1590/S1677-5538.IBU.2022.0132
- 36.** Elton D.C., Turkbey E.B., Pickhardt P.J., Summers R.M. A deep learning system for automated kidney stone detection and volumetric segmentation on noncontrast CT scans // *Med Phys.* 2022. Vol. 49, N 4. P. 2545–2554. doi: 10.1002/mp.15518
- 37.** He Z., An L., Chang Z., Wu W. Comment on “Deep learning computer vision algorithm for detecting kidney stone composition” // *World J Urol.* 2021. Vol. 39, N 1. P. 291. doi: 10.1007/s00345-020-03181-4
- 38.** Doyle P.W., Kavoussi N.L. Machine learning applications to enhance patient specific care for urologic surgery // *World J Urol.* 2022. Vol. 40, N 3. P. 679–686. doi: 10.1007/s00345-021-03738-x
- 39.** Neymark A.I., Neymark B.A., Ershov A.V., et al. The use of intelligent analysis (IA) in determining the tactics of treating patients with nephrolithiasis // *Urologia Journal.* 2023. N 3915603231162881. doi: 10.1177/03915603231162881
- 40.** Kadlec A.O., Ohlander S., Hotaling J., et al. Nonlinear logistic regression model for outcomes after endourologic procedures: a novel predictor // *Urolithiasis.* 2014. Vol. 42, N 4. P. 323–330. doi: 10.1007/s00240-014-0656-1
- 41.** Black K.M., Law H., Aldoukhi A., et al. Deep learning computer vision algorithm for detecting kidney stone composition // *BJU Int.* 2020. Vol. 125, N 6. P. 920–924. doi: 10.1111/bju.15035
- 42.** Zhang G.M., Sun H., Xue H.D., et al. Prospective prediction of the major component of urinary stone composition with dual-source dual-energy CT in vivo // *Clin Radiol.* 2016. Vol. 71, N 11. P. 1178–1183. doi: 10.1016/j.crad.2016.07.012
- 43.** Chaytor R.J., Rajbabu K., Jones P.A., McKnight L. Determining the composition of urinary tract calculi using stone-targeted dual-energy CT: evaluation of a low-dose scanning protocol in a clinical environment // *Br J Radiol.* 2016. Vol. 89, N 1067. P. 20160408. doi: 10.1259/bjr.20160408
- 44.** Капанадзе Л.Б., Серова Н.С., Руденко В.И. Аспекты применения двухэнергетической компьютерной томографии в диагностике мочекаменной болезни // *REJR.* 2017. Т. 7, № 3. С. 165–173. EDN: ZWBLYL doi: 10.21569/2222-7415-2017-7-3-165-173
- 45.** Cui Y., Sun Z., Ma S., et al. Automatic Detection and Scoring of Kidney Stones on Noncontrast CT Images Using S.T.O.N.E. Nephrolithometry: Combined Deep Learning and Thresholding Methods // *Mol Imaging Biol.* 2021. Vol. 23, N 3. P. 436–445. doi: 10.1007/s11307-020-01554-0
- 46.** Okhunov Z., Friedlander J.I., George A.K., et al. S.T.O.N.E. nephrolithometry: novel surgical classification system for kidney calculi // *Urology.* 2013. Vol. 81, N 6. P. 1154–1159. doi: 10.1016/j.urology.2012.10.083
- 47.** Yildirim K., Bozdog P.G., Talo M., et al. Deep learning model for automated kidney stone detection using coronal CT images // *Comput Biol Med.* 2021. Vol. 135. P. 104569. doi: 10.1016/j.compbiomed.2021.104569
- 48.** Коденко М.Р., Решетников Р.В., Макарова Т.А. Инструмент оценки качества исследований диагностической точности алгоритмов искусственного интеллекта (QUADAS-CAD) // *Digital Diagnostics.* 2022. Т. 3, № 1S. С. 4–5. EDN: KNBHOJ doi: 10.17816/DD105567
- 49.** Schwartz F.R., Clark D.P., Ding Y., Ramirez-Giraldo J.C. Evaluating renal lesions using deep-learning based extension of dual-energy FoV in dual-source CT-A retrospective pilot study // *Eur J Radiol.* 2021. Vol. 139. P. 109734. doi: 10.1016/j.ejrad.2021.109734
- 50.** Li W., Diao K., Wen Y., et al. High-strength deep learning image reconstruction in coronary CT angiography at 70-kVp tube voltage significantly improves image quality and reduces both radiation and contrast doses // *Eur Radiol.* 2022. Vol. 32, N 5. P. 2912–2920. doi: 10.1007/s00330-021-08424-5
- 51.** Bae J.S., Lee J.M., Kim S.W., et al. Low-contrast-dose liver CT using low monoenergetic images with deep learning-based denoising for assessing hepatocellular carcinoma: a randomized controlled noninferiority trial // *Eur Radiol.* 2023. Vol. 33, N 6. P. 4344–4354. doi: 10.1007/s00330-022-09298-x

REFERENCES

1. Iliashenko OY, Lukyanchenko EL. Possibilities of using computer vision for data analytics in medicine. *Izvestiya of Saratov University. Mathematics. Mechanics. Informatics*. 2022;22(2):224–232. EDN: MCSLKQ doi: 10.18500/1816-9791-2022-22-2-224-232
2. Alekseeva MG, Zubov AI, Novikov MYu. Artificial intelligence in medicine. *Meždunarodnyj naučno-issledovatel'skij žurnal*. 2022;7(121):10–13. EDN: JMMMDf doi: 10.23670/IRJ.2022.121.7.038
3. Gusev AV, Vladzimirskyy AV, Sharova DE, Arzamasov KM, Khramov AE. Evolution of research and development in the field of artificial intelligence technologies for healthcare in the Russian Federation: results of 2021. *Digital Diagnostics*. 2022;3(3):178–194. EDN: KHWQWZ doi: 10.17816/DD107367
4. Wang L, Wang H, Huang Y, et al. Trends in the application of deep learning networks in medical image analysis: Evolution between 2012 and 2020. *Eur J Radiol*. 2022;146:110069. doi: 10.1016/j.ejrad.2021.110069
5. Alrefai N, Ibrahim O. Al Deep learning-based cancer classification for microarray data: A systematic review. *Journal of Theoretical and Applied Information Technology*. 2021;99:2312–2332. doi: 10.5281/zenodo.6126510
6. *Clinical trials of artificial intelligence systems (radiation diagnostics)*. Vasil'ev YuA, Vladzimirskyy AV, Sharova DE, editors. Moscow: GBUZ «NPKTs DiT DZM»; 2023. EDN: PUIJLD
7. Lee J, Kim KW, Kim SY, et al. Automatic detection method of hepatocellular carcinomas using the non-rigid registration method of multi-phase liver CT images. *J Xray Sci Technol*. 2015;23(3):275–288. doi: 10.3233/XST-150487
8. Patel BN, Boltyenkov AT, Martinez MG, et al. Cost-effectiveness of dual-energy CT versus multiphasic single-energy CT and MRI for characterization of incidental indeterminate renal lesions. *Abdom Radiol (NY)*. 2020;45(6):1896–1906. doi: 10.1007/s00261-019-02380-x
9. Marrero JA, Kulik LM, Sirlin CB, et al. Diagnosis, Staging, and Management of Hepatocellular Carcinoma: 2018 Practice Guidance by the American Association for the Study of Liver Diseases. *Hepatology*. 2018;68(2):723–750. doi: 10.1002/hep.29913
10. Ayuso C, Rimola J, Vilana R, et al. Diagnosis and staging of hepatocellular carcinoma (HCC): current guidelines. *Eur J Radiol*. 2018;101:72–81. doi: 10.1016/j.ejrad.2018.01.025
11. *Liver cancer (hepatocellular). Clinical guidelines*. ID 1. Approved by the Scientific and Practical Council of the Ministry of Health of the Russian Federation. 2022. Available from: https://cr.minzdrav.gov.ru/schema/1_3 (In Russ)
12. Rahman H, Bukht TFN, Imran A, et al. A Deep Learning Approach for Liver and Tumor Segmentation in CT Images Using ResUNet. *Bioengineering (Basel)*. 2022;9(8):368. doi: 10.3390/bioengineering9080368
13. Maqsood M, Bukhari M, Ali Z, et al. A Residual-Learning-Based Multi-Scale Parallel-Convolutions- Assisted Efficient CAD System for Liver Tumor Detection. *Mathematics*. 2021;9(10):1133. doi: 10.3390/math9101133
14. Khan RA, Luo Y, Wu FX. RMS-UNet: Residual multi-scale UNet for liver and lesion segmentation. *Artif Intell Med*. 2022;124:102231. doi: 10.1016/j.artmed.2021.102231
15. Affane A, Kucharski A, Chapuis P, et al. Segmentation of Liver Anatomy by Combining 3D U-Net Approaches. *Applied Sciences*. 2021;11(11):4895. doi: 10.3390/app11114895
16. Han X, Wu X, Wang S, et al. Automated segmentation of liver segment on portal venous phase MR images using a 3D convolutional neural network. *Insights Imaging*. 2022;13(1):26. doi: 10.1186/s13244-022-01163-1
17. Wang J, Zhang X, Guo L, et al. Multi-scale attention and deep supervision-based 3D UNet for automatic liver segmentation from CT. *Math Biosci Eng*. 2023;20(1):1297–1316. doi: 10.3934/mbe.2023059
18. Kashala KG, Song Y, Liu Z. Optimization of FireNet for Liver Lesion Classification. *Electronics*. 2020;9(8):1237. doi: 10.3390/electronics9081237
19. Trivizakis E, Manikis GC, Nikiforaki K, et al. Extending 2-D Convolutional Neural Networks to 3-D for Advancing Deep Learning Cancer Classification With Application to MRI Liver Tumor Differentiation. *IEEE J Biomed Health Inform*. 2019;23(3):923–930. doi: 10.1109/JBHI.2018.2886276
20. Zhou J, Wang W, Lei B, et al. Automatic Detection and Classification of Focal Liver Lesions Based on Deep Convolutional Neural Networks: A Preliminary Study. *Front Oncol*. 2021;10:581210. doi: 10.3389/fonc.2020.581210
21. Rela M, Rao SN, Patil RR. Performance analysis of liver tumor classification using machine learning algorithms. *International Journal of Advanced Technology and Engineering Exploration*. 2022;9(86):143–154. doi: 10.19101/IJATEE.2021.87465
22. Oberai A, Varghese B, Cen S, et al. Deep learning based classification of solid lipid-poor contrast enhancing renal masses using contrast enhanced CT. *Br J Radiol*. 2020;93(1111):20200002. doi: 10.1259/bjr.20200002
23. Lin Z, Cui Y, Liu J, et al. Automated segmentation of kidney and renal mass and automated detection of renal mass in CT urography using 3D U-Net-based deep convolutional neural network. *Eur Radiol*. 2021;31(7):5021–5031. doi: 10.1007/s00330-020-07608-9
24. Toda N, Hashimoto M, Arita Y, et al. Deep Learning Algorithm for Fully Automated Detection of Small (≤ 4 cm) Renal Cell Carcinoma in Contrast-Enhanced Computed Tomography Using a Multicenter Database. *Invest Radiol*. 2022;57(5):327–333. doi: 10.1097/RLI.0000000000000842
25. Ding Y, Chen Z, Wang Z, et al. Three-dimensional deep neural network for automatic delineation of cervical cancer in planning computed tomography images. *J Appl Clin Med Phys*. 2022;23(4):e13566. doi: 10.1002/acm2.13566
26. Zhu XL, Shen HB, Sun H, et al. Improving segmentation and classification of renal tumors in small sample 3D CT images using transfer learning with convolutional neural networks. *Int J Comput Assist Radiol Surg*. 2022;17(7):1303–1311. doi: 10.1007/s11548-022-02587-2
27. Hsiao CH, Sun TL, Lin PC, et al. A deep learning-based precision volume calculation approach for kidney and tumor segmentation on computed tomography images. *Comput Methods Programs Biomed*. 2022;221:106861. doi: 10.1016/j.cmpb.2022.106861
28. Hsiao CH, Lin PC, Chung LA, et al. A deep learning-based precision and automatic kidney segmentation system using efficient feature pyramid networks in computed tomography

- images. *Comput Methods Programs Biomed.* 2022;221:106854. doi: 10.1016/j.cmpb.2022.106854
29. Islam MN, Hasan M, Hossain MK, et al. Vision transformer and explainable transfer learning models for auto detection of kidney cyst, stone and tumor from CT-radiography. *Sci Rep.* 2022;12(1):11440. doi: 10.1038/s41598-022-15634-4
30. Yang L, Gao L, Arefan D, et al. A CT-based radiomics model for predicting renal capsule invasion in renal cell carcinoma. *BMC Med Imaging.* 2022;22(1):15. doi: 10.1186/s12880-022-00741-5
31. Shehata M, Alksas A, Abouelkheir RT, et al. A Comprehensive Computer-Assisted Diagnosis System for Early Assessment of Renal Cancer Tumors. *Sensors (Basel).* 2021;21(14):4928. doi: 10.3390/s21144928
32. Kulikovskiy VF, Shkodkin SV, Batishchev SA, et al. Modern research and thinking about the epidemiology and pathogenesis of urolithiasis. *Nauchnyi rezul'tat. Meditsina i farmatsiya.* 2016;2(4):4–12. EDN: NSGAXL doi: 10.18413/2313-8955-2016-2-4-4-12
33. Gadzhiev N, Prosyannikov M, Malkhasyan V, et al. Urolithiasis prevalence in the Russian Federation: analysis of trends over a 15-year period. *World J Urol.* 2021;Vol. 39(10):3939–3944. doi: 10.1007/s00345-021-03729-y
34. *Urology. Russian Clinical Recommendations.* Alyaev YuG, Glybochko PV, Pushkar' DYu, editors. Moscow: GEOTARMedia; 2016. (In Russ).
35. Caglayan A, Horsanali MO, Kocadurdu K, et al. Deep learning model-assisted detection of kidney stones on computed tomography. *Int Braz J Urol.* 2022;48(5):830–839. doi: 10.1590/S1677-5538.IBU.2022.0132
36. Elton DC, Turkbey EB, Pickhardt PJ, Summers RM. A deep learning system for automated kidney stone detection and volumetric segmentation on noncontrast CT scans. *Med Phys.* 2022;49(4):2545–2554. doi: 10.1002/mp.15518
37. He Z, An L, Chang Z, Wu W. Comment on “Deep learning computer vision algorithm for detecting kidney stone composition”. *World J Urol.* 2021;39(1):291. doi: 10.1007/s00345-020-03181-4
38. Doyle PW, Kavoussi NL. Machine learning applications to enhance patient specific care for urologic surgery. *World J Urol.* 2022;40(3):679–686. doi: 10.1007/s00345-021-03738-x
39. Neymark AI, Neymark BA, Ershov AV, et al. The use of intelligent analysis (IA) in determining the tactics of treating patients with nephrolithiasis. *Urologia Journal.* 2023;(39)15603231162881. doi: 10.1177/03915603231162881
40. Kadlec AO, Ohlander S, Hotaling J, et al. Nonlinear logistic regression model for outcomes after endourologic procedures: a novel predictor. *Urolithiasis.* 2014;42(4):323–330. doi: 10.1007/s00240-014-0656-1
41. Black KM, Law H, Aldoukhi A, et al. Deep learning computer vision algorithm for detecting kidney stone composition. *BJU Int.* 2020;125(6):920–924. doi: 10.1111/bju.15035
42. Zhang GM, Sun H, Xue HD, et al. Prospective prediction of the major component of urinary stone composition with dual-source dual-energy CT in vivo. *Clin Radiol.* 2016;71(11):1178–1183. doi: 10.1016/j.crad.2016.07.012
43. Chaytor RJ, Rajbabu K, Jones PA, McKnight L. Determining the composition of urinary tract calculi using stone-targeted dual-energy CT: evaluation of a low-dose scanning protocol in a clinical environment. *Br J Radiol.* 2016;89(1067):20160408. doi: 10.1259/bjr.20160408
44. Kapanadze LB, Serova NS, Rudenko VI. Application of dual-energy computer tomography in diagnostics of urolithiasis. *REJR.* 2017;7(3):165–173. EDN: ZWBLYL doi: 10.21569/2222-7415-2017-7-3-165-173
45. Cui Y, Sun Z, Ma S, et al. Automatic Detection and Scoring of Kidney Stones on Noncontrast CT Images Using S.T.O.N.E. Nephrolithometry: Combined Deep Learning and Thresholding Methods. *Mol Imaging Biol.* 2021;23(3):436–445. doi: 10.1007/s11307-020-01554-0
46. Okhunov Z, Friedlander JI, George AK, et al. S.T.O.N.E. nephrolithometry: novel surgical classification system for kidney calculi. *Urology.* 2013;81(6):1154–1159. doi: 10.1016/j.urology.2012.10.083
47. Yildirim K, Bozdag PG, Talo M, et al. Deep learning model for automated kidney stone detection using coronal CT images. *Comput Biol Med.* 2021;135:104569. doi: 10.1016/j.compbiomed.2021.104569
48. Kodenko MR, Reshetnikov RV, Makarova TA. Modification of quality assessment tool for artificial intelligence diagnostic test accuracy studies (QUADAS-CAD). *Digital Diagnostics.* 2022;3(1S):4–5. EDN: KNBHOJ doi: 10.17816/DD105567
49. Schwartz FR, Clark DP, Ding Y, Ramirez-Giraldo JC. Evaluating renal lesions using deep-learning based extension of dual-energy FoV in dual-source CT-A retrospective pilot study. *Eur J Radiol.* 2021;139:109734. doi: 10.1016/j.ejrad.2021.109734
50. Li W, Diao K, Wen Y, et al. High-strength deep learning image reconstruction in coronary CT angiography at 70-kVp tube voltage significantly improves image quality and reduces both radiation and contrast doses. *Eur Radiol.* 2022;32(5):2912–2920. doi: 10.1007/s00330-021-08424-5
51. Bae JS, Lee JM, Kim SW, et al. Low-contrast-dose liver CT using low monoenergetic images with deep learning-based denoising for assessing hepatocellular carcinoma: a randomized controlled noninferiority trial. *Eur Radiol.* 2023;33(6):4344–4354. doi: 10.1007/s00330-022-09298-x

ОБ АВТОРАХ

* **Нечаев Николай Борисович**, канд. мед. наук;
адрес: Россия, 127051, г. Москва, ул. Петровка, д. 24, стр. 1;
ORCID: 0009-0007-9219-7726;
eLibrary SPIN: 3232-1545;
e-mail: NechaevNB@zdrav.mos.ru

AUTHORS' INFO

* **Nikolay B. Nechaev**, MD, Cand. Sci. (Medicine);
address: 24-1 Petrovka Str., Moscow, 127051, Russia;
ORCID: 0009-0007-9219-7726;
eLibrary SPIN: 3232-1545;
e-mail: NechaevNB@zdrav.mos.ru

* Автор, ответственный за переписку / Corresponding author

Васильев Юрий Александрович, канд. мед. наук;
ORCID: 0000-0002-0208-5218;
eLibrary SPIN: 4458-5608;
e-mail: npcmr@zdrav.mos.ru

Владимирский Антон Вячеславович, д-р мед. наук,
профессор;
ORCID: 0000-0002-2990-7736;
eLibrary SPIN: 3602-7120;
e-mail: VladzimirskijAV@zdrav.mos.ru

Арзамасов Кирилл Михайлович, канд. мед. наук;
ORCID: 0000-0001-7786-0349;
eLibrary SPIN: 3160-8062;
e-mail: ArzamasovKM@zdrav.mos.ru

Шихмуратов Давид Уружбегович;
ORCID: 0000-0003-1597-5786;
eLibrary SPIN: 9641-0913;
e-mail: ShikhmuradovDU@zdrav.mos.ru

Панкратов Андрей Вячеславович;
ORCID: 0009-0008-4741-4530;
e-mail: PankratovAV3@zdrav.mos.ru

Ульянов Илья Владимирович;
ORCID: 0000-0002-8330-6069;
eLibrary SPIN: 5898-3242;
e-mail: UlyanovIV2@zdrav.mos.ru

Нечаев Николай Борисович, канд. мед. наук;
ORCID: 0009-0007-9219-7726;
eLibrary SPIN: 3232-1545;
e-mail: NechaevNB@zdrav.mos.ru

Yuriy A. Vasilev, MD, Cand. Sci. (Medicine);
ORCID: 0000-0002-0208-5218;
eLibrary SPIN: 4458-5608;
e-mail: npcmr@zdrav.mos.ru

Anton V. Vladzymyrskyy, MD, Dr. Sci. (Medicine),
Professor;
ORCID: 0000-0002-2990-7736;
eLibrary SPIN: 3602-7120;
e-mail: VladzimirskijAV@zdrav.mos.ru

Kirill M. Arzamasov, MD, Cand. Sci. (Medicine);
ORCID: 0000-0001-7786-0349;
eLibrary SPIN: 3160-8062;
e-mail: ArzamasovKM@zdrav.mos.ru

David U. Shikhmuradov, MD;
ORCID: 0000-0003-1597-5786;
eLibrary SPIN: 9641-0913;
e-mail: ShikhmuradovDU@zdrav.mos.ru

Andrey V. Pankratov, MD;
ORCID: 0009-0008-4741-4530;
e-mail: PankratovAV3@zdrav.mos.ru

Iliya V. Ulyanov, MD;
ORCID: 0000-0002-8330-6069;
eLibrary SPIN: 5898-3242;
e-mail: UlyanovIV2@zdrav.mos.ru

Nikolay B. Nechaev, MD, Cand. Sci. (Medicine);
ORCID: 0009-0007-9219-7726;
eLibrary SPIN: 3232-1545;
e-mail: NechaevNB@zdrav.mos.ru

Приложение 1

Таблица 1. Архитектуры и диагностические метрики алгоритмов глубокого машинного обучения для определения патологии органов брюшной полости методами визуализации

1	2	3	4	5
Клиническая задача	Авторы, год	Объём выборки для тестирования	Используемая архитектура	Заявленные показатели диагностической точности
Сегментация образований печени и её структур	M. Maqsood и соавт., 2021 [13]	4 иссл.	ResUNet с использованием Multi-scale parallel convolution blocks после Res blocks	Сегментация печени: – Коэффициент сходства Дайса: 0,77 – Точность: 93%
	R.Z. Khan и соавт., 2022 [14]	3 иссл. (Dicadb) 19 иссл. (LITS) 4 иссл. (Silver07) 1 иссл. (Chaos)	ResUNet. В базовом блоке три последовательных слоя Conv2D с расширением ядра свёртки (три скорости расширения — 1, 2 и 4)	1) Сегментация печени, коэффициент сходства Дайса: – 0,97 на наборе данных Dicadb; – 0,97 на наборе данных LITS; – 0,97 на наборе данных Silver07; – 0,95 на наборе данных Chaos 2) Сегментация образований печени, коэффициент сходства Дайса: – 0,92 на наборе данных Dicadb; – 0,87 на наборе данных LITS
	H. Rahman и соавт., 2022 [12]	4 иссл.	Последовательное использование ResUNet для сегментации печени, с последующим использованием полученных данных на другой ResUNet для сегментации образований	Сегментация печени и её новообразований: – Коэффициент сходства Дайса: 0,99; – Точность: 99,6%
	A. Alfane и соавт., 2021 [15]	1 иссл.	Три модификации 3D U-Net: 1) 3D U-Net, классическая сеть 2) 3D MultiRes U-Net. Перед Skip Connection используется блок Resolution Path. Внутри Conv блока: три связанных 3D-свёртки размерами 3×3×3 (в первой — 32 фильтра, в двух последующих — по 16), которые объединяются, нормализуются и суммируются с входными данными, прошедшими через Conv3D (размер 1×1×1, 64 фильтра). За этим следует сигмовидная активация 3) 3D Dense U-Net — с объединением по типу остаточной связи после каждого Conv слоя	Сегментация печени, коэффициент сходства Дайса: – 0,86 — сеть 3D MultiRes U-Net; – 0,84 — сеть 3D Dense U-Net; – 0,73 — сеть 3D U-Net
	J. Wang и соавт., 2023 [17]	8 иссл. (Dicadb) 15 иссл. (LITS)	3D MAD-UNet — используется Long-Short Skip Connection (LSSC) и Attention module для всех уровней декодера	Сегментация образований печени, коэффициент сходства Дайса: – 0,96 — сеть 3D U-Net + LSSC + MA на наборе данных LITS; – 0,96 — сеть 3D U-Net + LSSC + MA на наборе данных Dicadb; – 0,92 — сеть 3D U-Net на наборе данных LITS; – 0,89 — сеть 3D U-Net на наборе данных Dicadb

Таблица 1. Продолжение

1	2	3	4	5
Классификация образований печени по нозологиям	K.G. Kashala и соавт., 2020 [18]	250 иссл.	Модифицированная SqueezeNet — модель, где добавляется обход после блоков 2, 4, 6 и 8, а также используется Conv2D (1×1) перед объединением expand блоков	– Точность: 81,8%; – F1-мера: 0,80
	J. Zhou и соавт., 2021 [20]	154 иссл.	Для сегментации использовалась 2,5D Faster R-CNN; для классификации использовали 3D ResNet-18 (модификация, основанная на Conv3D)	– Точность: 82,5% при определении доброкачественное/злокачественное новообразование; – Точность: 73,4% при определении одной из 6 патологий (гепатоцеллюлярный рак, холангиокарцинома, метастаз, гемангиома, гиперплазия, киста)
	M. Rela и соавт., 2022 [21]	14 иссл.	Метод опорных векторов, метод k-ближайших соседей	1) Метод опорных векторов: – Точность: 84,6%; – F1-мера: 0,80 2) Метод k-ближайших соседей: – Точность: 76,92%; – F1-мера: 0,76
Сегментация почек и новообразований	Y. Ding и соавт., 2022 [25]	30 иссл.	– U-Net – V-Net — модификация, где используются блоки ResNet, работающие с 3D-изображением	Сегментация почек: 1) Коэффициент сходства Дайса для левой почки: – 0,93 — сеть U-Net; – 0,92 — сеть V-Net 2) Коэффициент сходства Дайса для правой почки: – 0,91 — сеть U-Net; – 0,92 — сеть V-Net
	Z. Lin и соавт., 2021 [23]	66 иссл.	3D U-Net	1) Сегментация почек: Коэффициент сходства Дайса — 0,97 2) Сегментация опухолей почек: Коэффициент сходства Дайса — 0,84 3) Сегментация кист почек: Коэффициент сходства Дайса — 0,54

Таблица 1. Продолжение

1	2	3	4	5
Сегментация почек и новообразований	С.Н. Hsiao и соавт., 2022 [27] 90 иссл.		U-Net, где в качестве блоков кодировщика использовались архитектуры из ResNet-41 или EffectiveNet	Сегментация почек: 1) Коэффициент сходства Дайса (данные с предобработкой и U-Net с кодировщиком): – 0,96 — EfficientNet-B7; – 0,95 — ResNet-41; – 0,95 — EfficientNet-B4; – 0,95 — EfficientNet-B4, дообученная 2) Коэффициент сходства Дайса (данные без предобработки и U-Net с кодировщиком): – 0,95 — EfficientNet-B4, дообученная; – 0,93 — ResNet-41; – 0,29 — EfficientNet-B4; – 0,27 — EfficientNet-B7 3) Сегментация новообразований почек: Коэффициент сходства Дайса — 0,41 (EfficientNet-B5)
				Сегментация почек и их опухолей: Коэффициент сходства Дайса — 0,95
				Классификация новообразований почек: 1) Архитектура VGG16: – Точность — 98,2%; – F1-мера средняя — 0,98; – AUC средняя — 0,99 2) Архитектура Inception v3: – Точность — 61,6%; – F1-мера средняя — 0,59; – AUC средняя — 0,85 3) Архитектура ResNet50: – Точность — 73,8%; – F1-мера средняя — 0,74; – AUC средняя — 0,93 4) Архитектура EANet: – Точность — 77,0%; – F1-мера средняя — 0,77; – AUC средняя — 0,96 5) Архитектура Swin Transformers: – Точность — 99,3%; – F1-мера средняя — 0,99; – AUC средняя — 0,99 6) Архитектура CCT: – Точность — 96,5%; – F1-мера средняя — 0,97; – AUC средняя — 0,99
Сегментация и классификация новообразований почки по нозологиям	М.Н. Islam и соавт., 2022 [29]	56 иссл. (KITS19) ~1000 изобр.	EffectiveNet-B5 (энкодер); Feature pyramid network (декодер) 6 архитектур: – Модифицированная VGG16; – Inception v3; – ResNet50; – EANet; – Swin Transformers; – CCT	

Таблица 1. Продолжение

1	2	3	4	5
	Toda N. и соавт., 2022 [24]	132 испл.	2D U-Net для сегментации почек; 3D U-Net для сегментации и классификации образований	Классификация образований почек: – Точность — 87,5%; – AUC — 0,93
Сегментация и классификация новообразований почки по нозологиям	Zhu X.L. и соавт., 2022 [26]	20 испл.	FS-net: исходные данные проводятся через дообученную 3D U-Net, полученная маска объединяется с исходным данными и проводится через дообученную 3D U-Net. Из полученной маски делаются сегментированные данные почки и области почки. Сегментированные данные подвергаются текстурному анализу для получения признаков. Область почки пропускают через дообученную 3D ResNet для получения признаков. Полученные признаки используют в методе опорных векторов	1) Сегментация почек: – коэффициент сходства Дайса — 0,97 (KITS19); – коэффициент сходства Дайса — 0,97 (собственный набор данных) 2) Сегментация опухолей почек: – коэффициент сходства Дайса — 0,79 (KITS19); – коэффициент сходства Дайса — 0,77 (собственный набор данных)
	L. Yang и соавт., 2022 [30]	120 испл.	Из сегментированных вручную почек с образованием выделялись признаки с помощью библиотеки radiomics. Признаки пропускались через сеть прямого распространения	Классификация опухолей почек, AUC: – 0,76 — в нативной фазе; – 0,79 — в кортикомедулярной фазе; – 0,77 — в нефрографической фазе
Классификация новообразований почки и их характеристик	M. Shehata и соавт., 2021 [31]	–	Из сегментированных вручную почек с образованием выделялись признаки: морфологические (оценка формы), текстурные и функциональные. Признаки проходят через сеть прямого распространения, классифицирующую на добро- и злокачественную природу. При злокачественном характере признаки пропускаются через сеть прямого распространения для определения светло- и несветлоклеточного рака	Классификация опухолей почек на добро- и злокачественные: – F1-мера — 0,98 Классификация рака почек: – Точность — 89,6%
Определение уролитиазов на компьютерной томографии	A. Saglaayan и соавт., 2022 [35]	–	xResNet50	Камни <1 см: – Точность — 85%; – F1-мера — 0,85 Камни 1–2 см: – Точность — 89%; – F1-мера — 0,89 Камни >2 см: – Точность — 93%; – F1-мера — 0,93

Таблица 1. Окончание

1	2	3	4	5
Определение уролитиазов на компьютерной томографии	C. Daniel и соавт., 2022 [36]	90 иссл.	3D U-Net для сегментации почек, процедура удаления шума, обрезание области интереса, 13-слойная 3D CNN для классификации	– AUC: 0,95; – Специфичность: 0,91
	Y. Cui и соавт., 2021 [45]	117 иссл.	Последовательное использование 3D U-Net архитектур для сегментации почек. Полученные данные используются в пяти 3D U-Net архитектурах, каждая из которых отвечает за классификацию по одному из параметров шкалы S.T.O.N.E.	Сегментация почек и синусов: – Коэффициент сходства Дайса — 0,93 Определение конкрементов: – Точность — 90,3%; – AUC — 0,96
	K. Yildirim и соавт., 2021 [47]	100 иссл.	xResNet50	– Точность: 97%; – F1-мера: 0,97

DOI: <https://doi.org/10.17816/DD625319>

Эпистемический статус искусственного интеллекта в медицинских практиках: этические вызовы

А.В. Баева

Московский государственный университет имени М.В. Ломоносова, Москва, Россия

АННОТАЦИЯ

В современных научных исследованиях в последнее время всё чаще появляются дискуссии о том, что в связи с развитием технологий искусственного интеллекта встают вопросы об объективности, правдоподобности и достоверности знания, а также о том, не заменяют ли эти технологии фигуру эксперта как ту инстанцию, которая до сих пор выступала гарантом объективности и центром принятия решений. Современные историки науки Л. Дастон и П. Галисон в своей книге, посвящённой истории научной объективности, говорят о сменяемости «эпистемических добродетелей», в качестве одной из которых с определённого момента утвердилась и объективность. При этом выдвижение той или иной добродетели, регулирующей научную самость, то есть выступающей нормативным принципом для учёного при выборе способа видения и научной практики, зависит от принятия решений в трудных случаях, требующих воли и ограничения самости. В этом смысле эпистемология соединяется с этикой: учёный, руководствуясь определёнными моральными принципами, отдаёт предпочтение тому или иному способу поведения, выбирая, например, не более точное изображение, сделанное от руки, а неретушированную фотографию, возможно, нечёткую, но полученную механически, а значит — более объективную и свободную от какой-либо примеси субъективности. В этой связи небезынтересным представляется эпистемический статус современных технологий на основе искусственного интеллекта, которые всё больше берут на себя функции научной самости, в том числе и в части оказания влияния на принятие конечных решений и получение объективного знания. Так, например, в области медицины роботизированные аппараты уже оказывают существенную поддержку: им передаётся часть функций, например, врача первого звена для сбора и анализа стандартизированных данных о пациенте и диагностики. Есть предположение, что в ближайшее время всё больше обязанностей будет передаваться искусственному интеллекту: обработка данных, разработка новых лекарств и способов лечения, налаживание дистанционного взаимодействия с пациентом и др. Значит ли это, что научная самость может быть заменена алгоритмами на основе искусственного интеллекта, а на смену объективности придёт другая эпистемическая добродетель, окончательно разрывающая связь этики и эпистемологии, — этот вопрос нуждается в исследовании.

Ключевые слова: современные научные практики; объективность; эпистемическая добродетель; научная самость; технологии на основе искусственного интеллекта.

Как цитировать:

Баева А.В. Эпистемический статус искусственного интеллекта в медицинских практиках: этические вызовы // Digital Diagnostics. 2024. Т. 5, № 1. С. 120–132. DOI: <https://doi.org/10.17816/DD625319>

DOI: <https://doi.org/10.17816/DD625319>

Epistemic status of artificial intelligence in medical practice: Ethical challenges

Angelina V. Baeva

Lomonosov Moscow State University, Moscow, Russia

ABSTRACT

Advances in artificial intelligence have raised controversy in modern scientific research regarding the objectivity, plausibility, and reliability of knowledge, and whether these technologies will replace the expert figure as the authority that has so far served as a guarantor of objectivity and the center of decision-making. In their book on the history of scientific objectivity, modern historians of science L. Duston and P. Galison discuss the interchangeability of “epistemic virtues,” which now include objectivity. Moreover, selecting one or another virtue governing the scientific self, i.e., serving as a normative principle for a scientist when adopting a perspective or scientific practice, depends on making decisions in difficult cases that require will and self-restriction. In this sense, epistemology and ethics are intertwined: a scientist, guided by certain moral principles, prefers one or another course of action, such as choosing not a more accurate hand-drawn image but an unretouched photograph, perhaps fuzzy, but obtained mechanically, which means it is more objective and free of subjectivity. In this regard, the epistemic standing of modern artificial intelligence technologies, which increasingly perform the functions of the scientific self, including influencing ultimate decision-making and obtaining objective knowledge, is intriguing. For example, in medicine, robotic devices considerable support and are assigned some of the responsibilities of a primary care physician, such as collecting and analyzing standardized patient data and diagnosis. It is expected that artificial intelligence will take on more tasks such as data processing, development of new drugs and treatment methods, and remote interaction with patients. It remains to be seen whether this implies that the scientific self can be replaced by artificial intelligence algorithms and another epistemic virtue will replace objectivity, thus breaking the link between ethics and epistemology.

Keywords: modern scientific practices; objectivity; epistemic virtue; scientific self; artificial intelligence technologies.

To cite this article:

Baeva AV. Epistemic status of artificial intelligence in medical practice: Ethical challenges. *Digital Diagnostics*. 2024;5(1):120–132.

DOI: <https://doi.org/10.17816/DD625319>

Submitted: 26.12.2023

Accepted: 13.02.2024

Published online: 11.03.2024

DOI: <https://doi.org/10.17816/DD625319>

人工智能在医疗实践中的认识论地位：伦理挑战

Angelina V. Baeva

Lomonosov Moscow State University, Moscow, Russia

摘要

最近，在现代科学研究中越来越多地讨论认为，随着人工智能技术的发展，知识的客观性、可信度和可靠性出现了问题，以及这些技术是否会取代专家的问题。迄今为止，专家一直是客观性的保证和决策中心。现代科学史学家L. Daston和P. Galison在他们关于科学客观性历史的著作中谈到了“认识论美德”的更迭。客观性从某个时刻就确立为其中之一。美德是科学家选择理解方式和科学实践的规范性原则。管理科学信念的特定美德的弘扬过程取决于科学家在需要意志和信念限制的困难情况下做出的决策。从这个意义上说，认识论与伦理学是相通的。科学家在某些道德原则的指导下，倾向于这样或那样的行为方式。例如，科学家选择一张未经修饰的照片，而不是更精确的手绘图像。照片可能模糊不清，但它是通过机械方式获得的，这意味着这样的照片更加客观，未受到任何主观因素的影响。在这方面，以人工智能为基础的现代技术的认识论地位很有意思。这些人工智能技术越来越多地承担科学信念的功能，包括在影响最终决策和获取客观知识方面。例如，在医学领域，机器人设备已经开始提供重要的支持。一些功能被转移到这些机器上，例如一线医生收集和分析病人标准数据的功能和诊断功能。有一种假设认为，在不久的将来，越来越多的职责将移交给人工智能：数据处理、新药物和新疗法的开发、与病人建立远程互动等等。这是否意味着科学可能会被基于人工智能的算法所取代，客观性将被另一种最终打破伦理学与认识论之间联系的认识论美德所取代。这是一个需要探讨的问题。

关键词：现代科学实践；客观性；认识论美德；科学信念；基于人工智能的技术。

引用本文：

Baeva AV. 人工智能在医疗实践中的认识论地位：伦理挑战. *Digital Diagnostics*. 2024;5(1):120–132. DOI: <https://doi.org/10.17816/DD625319>

收到: 26.12.2023

接受: 13.02.2024

发布日期: 11.03.2024

ВВЕДЕНИЕ

Применение технологий на основе искусственного интеллекта (ИИ) в современных научных (в частности — медицинских) практиках¹ ставит перед исследователями науки ряд проблем: каков эпистемический статус ИИ, и какие этические вызовы в связи с определением этого статуса возникают. Вопрос эпистемического статуса ИИ нуждается в прояснении, поскольку в связи с активным внедрением ИИ в научные практики неизбежно возникает опасение, что агентность технологий ставит под угрозу как агентность самой фигуры врача как инстанции, принимающей решение и стремящейся к объективному взгляду, так и саму объективность как эпистемическую добродетель², которая ассоциируется с наукой.

Проект исторической концепции объективности Л. Да-стон и П. Галисона [1], в котором авторы демонстрируют историчность объективности как эпистемической добродетели на примере исследования конкретных материальных научных практик, а именно практик создания визуальных образов для естественно-научных атласов, строится с опорой на два основных аспекта: эпистемические добродетели (в частности — объективность) и визуальность.

«Внимание к той или иной форме научного видения выводит на первый план два вопроса. Какие практики нужны, чтобы производить изображения такого типа? И какие практики нужны, чтобы культивировать научную самость, делающую такое видение возможным? История научного видения всегда требует такого двойного движения: с одной стороны, к развёртыванию эпистемологии образов, с другой — к культивируемой этике научной самости. Верность природе всегда была тройным обязательством: визуальным, эпистемологическим и этическим. Что происходит, когда верность нарушена и природа сливается с артефактом? Пришла пора взглянуть на современные научные атласы: образы, в которых

процесс изготовления является одновременно процессом видения» [1]. Эти два аспекта оказываются тесно связанными в один проблемный узел конкретными практиками визуализации рабочих объектов науки³.

Изменения в характере изображений и практик показывают ту или иную эпистемическую добродетель в действии. В этой связи изменение визуализации с помощью применения цифровых технологий и технологий на основе ИИ позволяет поставить вопрос о трансформации как эпистемической добродетели объективности, так и научной самости. Различные способы визуализации (использование диаграмм, карт, фотографий, составление атласов) становятся одной из фундаментальных и неотъемлемых частей выстраивания аргументации в современных научных исследованиях. При этом визуализация, благодаря возможностям новых цифровых технологий, выступает не просто иллюстрацией, а непосредственно формой исследования. Переходом от репрезентации к презентации ознаменован новый способ видения и научной практики в целом: манипулирование визуальным образом начинает означать то же, что и манипулирование самим изображаемым или наблюдаемым объектом. Компьютерное моделирование и новые методы визуализации стали очередным революционным прорывом в научных практиках после наблюдения и эксперимента. В этой связи естественным образом возникают вопросы относительно того, каково настоящее и возможное будущее объективности как эпистемической добродетели в эпоху цифровизации и инноваций в науке в условиях, когда техника и технологии начинают играть существенную роль в производстве научного знания, не столько открывая, сколько изобретая факты. Что представляют собой новые научные практики, и какими могут быть новые добродетели? Если практики укоренены исторически, то как изменяются добродетели? Связано ли изменение добродетелей с изменением целей/благ, лежащих в основе той или иной практики? Может ли чем-то ещё, кроме добродетелей, определяться

¹ Говоря о современных научных практиках, мы подразумеваем принципиально усложнённое и эмпирически многообразное пространство науки, которое включает, помимо пропозициональных режимов производства знания, различные непропозициональные формы в виде графиков, диаграмм, визуальных образов и т.д. Одним из ярких примеров, демонстрирующих, как научная практика не столько познаёт свой объект, сколько создаёт его практически, является исследовательский проект А. Мол, посвящённый множественности онтологии медицинских практик на примере осуществления в разветвлённых практиках такой болезни, как атеросклероз [2].

² Объективность как эпистемическая добродетель возникает на определённом историческом этапе сложной координации наблюдателя и практики наблюдения и находит выражение в определённых изобразительных практиках и технологиях визуализации, поскольку эпистемические добродетели как устойчивые черты характера культивируются в конкретных исследовательских практиках, а через них, в свою очередь, складывается определённый тип научной самости. Каждая практика, совершаемая научной самостью, направлена на достижение какого-то блага. Таким образом, устойчивые практики — это то, что позволяет видеть перемены в эпистемических добродетелях.

³ «Говорить от имени природы самой по себе» становится лозунгом нового вида научной объективности, который появляется во второй половине XIX века. Опасаясь человеческого вмешательства между природой и наукой, французский физиолог Этьен-Жюль Маре, изучающий множество визуальных методов в науке, и его современники обратились к механическому воспроизводству образов для устранения подозрительных опосредований. Они заручаются полиграфами, фотографиями и другими приспособлениями в попытке создать атласы — «библию наблюдаемой науки». Атласы задают новый вектор в разговоре о научной объективности [3]. Атласы ставят рабочие объекты наукам зрения, тренируя глаз выделять определённые виды объектов в качестве образцовых (то, что можно назвать «типичным») и рассматривать их определённым образом. В случае атласов, которые представляют изображения, полученные новыми инструментами (например, рентгеновские атласы в начале XX века), всё принадлежащее атласу поле должно читаться тоже по-новому. Поскольку атласы приучают глаз, они по необходимости визуальны, даже в тех дисциплинах, где существенную роль играют другие ощущения [3].

научная самость, и как она может изменяться, дополняться технологиями на основе ИИ?

СОВРЕМЕННЫЕ НАУЧНЫЕ ПРАКТИКИ: МАТЕРИАЛЬНОСТЬ И ЭПИСТЕМИЧЕСКИЙ СТАТУС АРТЕФАКТОВ

В современных научных практиках граница между объективным и субъективным, абстрактным и конкретным, открытым и сделанным стирается. Артефакты начинают играть существенную роль в формировании научного знания и оказывать влияние на его основные характеристики, в том числе объективность, которая перестаёт пониматься как абстрактная научная характеристика, не зависящая от субъекта. По мере развития технологий всё большей значимостью начинают обладать технические артефакты⁴, которые конструируются, например, в рамках научных лабораторий и обладают принципиально новыми свойствами для создания нового знания. Помимо функционального предназначения, одним из важнейших свойств артефактов считается материальность: артефакты не являются идеальными объектами, хотя сами при этом могут выступать инструментами формирования идеализаций. Кроме того, артефакты по своей природе связаны с жизненным миром человека, культурной средой, исторической эпохой и социальными практиками, что, собственно, и делает артефакты интенционально зависимыми (онтологически, а не каузально) от процессов, происходящих в практиках взаимодействия с ними. При создании артефактов человек преобразовывает и приспосабливает природу, формируя новые объекты. Через изготовление и использование артефактов формируются практики преобразования и познания мира. Принимая во внимание специфические свойства и функции технических артефактов, используемых в научных практиках, можно говорить о том, что они сами представляют собой принципиально важный конституирующий элемент сохранения стабильности научного знания. Таким образом, «под артефактом стоит понимать элементы системы вещей, которые являются «вещественными» и позволяют репрезентировать

смыслы, специфичные для культуры, механизмы производства вещей, процессы обучения и овладения смыслами и метафорами, и позволяют культуре изменяться. Именно такие артефакты обладают онтологической значимостью, так как в них проявляются специфические смыслы культуры, которые без них не могли бы существовать и быть репрезентированы» [4].

Искусственность объекта не может быть объяснена только с точки зрения его сущностных характеристик, в отрыве от комплекса других объектов, отношений, программ — то есть обыденных условий для раскрытия объекта как артефакта. М. Полани формулирует наличие инструмента или сам инструмент в определённом смысле как то, что отлично от его пригодности в качестве объективного «механизма». Он становится своеобразным расширением человеческого тела: мы вписываем инструментарий в наше тело или расширяем наше тело таким образом, что сживаемся с этой вещью. Это телесное расширение инструмента, как отмечает М. Линч, Полани называет интериоризацией [6]. Проблема противопоставления «объективного» и «сделанного» вырастает из различия между артефактом и естественной объективностью, которое проблематизируется в лабораторных научных практиках⁵.

Анализируя артефакты в научных практиках, Линч выделяет позитивные и негативные артефакты. Первая группа артефактов характеризуется внешним вещественным проявлением (например, пятно на стекле микроскопа): в таком случае они принадлежат субъективным условиям наблюдения, то есть рассматриваются как зависящие от инструментальных условий восприятия. Линч выделяет несколько характерных особенностей таких артефактов. Прежде всего, они материальны, то есть видимы и доступны для считывания. Во-вторых, они повсеместны и воспроизводимы по своему внешнему виду как повседневные неприятности, населяющие работу по выполнению технической подготовки изображений. Кроме того, как только они обнаруживаются в качестве артефактов, они беспрепятственно могут быть отделены от адекватно сконструированных характеристик изображения (например, электронной микрофотографии). Наконец обнаружение таких артефактов инициирует их считывание, которое,

⁴ «Техническими артефактами являются объекты, созданные специально для того, чтобы служить определённой цели; естественные объекты появляются без вмешательства имеющих какие-либо намерения агентов. Артефакты существенным образом обладают интенциональными свойствами, а естественные объекты — нет» [5]. С одной стороны, принято считать, что артефактами являются объекты, созданные для определённой цели (в отличие от естественных объектов). Однако в исследованиях, посвящённых современной эпистемологии, справедливо отмечается, что техническим артефактом может быть не только искусственно сконструированная вещь, но и вполне естественный, живой организм, используемый для решения определённых задач. В этом случае следует признать, что конституирующим свойством артефакта будет не его искусственная природа, а его использование в человеческой познавательной деятельности. Функциональность артефакта — одно из его существенных свойств. «Артефактом является и вакцина, и адронный коллайдер, и палка-копалка. Все эти объекты связаны с жизненным миром человека, и именно это позволяет им быть техническими артефактами» [4].

⁵ Как отмечал К. Поппер, «объективность тесно связана с социальным аспектом научного метода, с тем фактом, что наука и научная объективность не могут быть результатом стремления отдельного учёного быть объективным. Это возможно только как результат деятельности сообщества учёных. Научная объективность может быть описана в интерсубъективном научном методе. Но этот социальный аспект науки почти полностью отвергается теми, кто называет себя социологами знания» [6].

как правило, ставит вопрос о том, учитывать ли обнаруженные артефакты в конечном итоге и использовать ли их в дальнейшей работе.

Однако, как отмечает Линч, есть некоторые проблемы с «этнографической» ориентацией на артефакты в лаборатории. Во-первых, легко заметить, что количество артефактов, представленных в отчётах в качестве примеров, не исчерпывается указанием всего, что может считаться искусственным в исследованиях. Кроме того, то, что считается искусственным, определяется зачастую тем, как оно представлено в отчётных записях. Например, нейронная ультраструктура может быть представлена в виде аналитической записи, которая наделяется статусом артефакта в поле нейронных сущностей, доступ к которым осуществляется через считывание этой записи. Особенности формата представления артефакта могут включать такие характеристики, как двухмерность фотографии; чёрно-белые текстурные вариации, которые придают очертание формам сфотографированного явления; последовательное расположение фотографических серий для изображения сплошной последовательности событий [6]. Там, где о записи можно говорить как о форме визуализации невидимого явления, артефакты во многих случаях были обнаружены в лабораторных отчётах о тех явлениях, которые ранее не предвиделись. Артефакты становились открытием в том смысле, что они зачастую возникали как новые явления в ранее не изученной области. Это, по определению Линча, так называемые ситуативные, или негативные, артефакты. Во всяком случае, пишет Линч, примеры таких артефактов, которые становились открытием, позволяют сделать вывод о том, что итог наблюдения или эксперимента во многом определяется теми условиями, в которых он производится.

Опираясь на приведённые специфические особенности позитивных и негативных артефактов и их роль в научных практиках, Линч приводит пример с обнаружением явления микроглии как артефакта [6]. Её «неправдоподобие» не было эмпирической невозможностью, но оно было единичным случаем в рамках более правдоподобной альтернативной версии. Теоретические предпосылки, которые привели к тому, что микроглия в капилляре была рассмотрена с особым вниманием (несколько фотографий, сделанных крупным планом, были сведены в единую серию), обязаны более детальному исследованию явления, чем это могло быть в противном случае. Проблемный характер фотографии микроглии не только был связан с фактом противоречия лабораторному предположению о том, как микроглия должна возникать в мозге, но также был усугублён наличием конкурирующего предположения, задокументированного фотографий. Клетка микроглии не только появилась в некотором роде путём,

необъяснимым в лабораторной версии физиологии мозга, но и могла быть приведена в качестве доказательства другого возможного объяснения. Размещение микроглии в капилляре стало скорее невольным созданием конструкцией, нежели схваченным образом реального положения дел [6].

Такой пример артефакта не был вещественным в позитивном смысле, поскольку о самой видимости речи не шло. Проблема была в другом понимании материальности. Прорастания аксона продемонстрировали материальное расширение в направлении, отличном от того, которое было принято лабораторными исследователями как неоспоримое, и в результате оно было оспорено с учётом альтернативного материального аргумента [6]. В данном случае артефакт был узнаваем с точки зрения определённой линии полемики относительно проросших аксонов и, соответственно, был предметом споров. В этом и подобных случаях артефакт был, по сути, не столько «вещью», сколько «анти-вещью» в рамках столкновения противоположных точек зрения. Артефактами, помимо «вещей», могли быть и возможности, возникающие в противовес принятым расчётам. Такие возможности были зачастую упомянуты скорее как отсутствующие в наблюдении, нежели как присутствующие (пятна, кляксы, размытия на фотографиях, которые могут быть рассмотрены как «вторжения»⁶). В таком случае артефакты фигурировали в ситуации неопределённости.

Негативные артефакты считаются не как вторжения, искажения или специфические дефекты в наблюдаемом поле, но как отсутствие желаемых результатов или эффектов. В случае с негативными артефактами отсутствие положительного результата эксперимента или процедуры наблюдения подразумевало адекватность произведённой лабораторной работы с учётом возможных непредвиденных обстоятельств, которые, в свою очередь, были признаны ответственными за полученный результат. Неудача, вызванная неопределённостью, провоцирует расследование, по какой причине не был получен желаемый результат. Неопределённость таких отрицательных результатов была рассмотрена Линчем как дополнение к необходимому техническому горизонту достижения объективности [6]. Неудача в работе несёт в себе переменные моральные коннотации, зависящие от локально выстроенных обстоятельств: в некоторых случаях они могут быть локализованы в более или менее объективных обстоятельствах.

Позитивные артефакты в виде вторжений в пространство видимости естественного феномена обнаруживаются в исследовательской работе, стремящейся избежать возможности субъективной ошибки. Негативные артефакты, поскольку они показывают, что работа является поиском неуловимого предмета, свидетельствуют о работе поиска.

⁶ Например, экспериментальный метод Г. Галилея (в отличие от эмпирического метода Ф. Бэкона) делал возможным взаимопереплетение умозрительных конструкций и эмпирических моделей благодаря технической деятельности. При этом производимое с помощью телескопа наблюдение пятен на солнце должно было отстаиваться как результат именно наблюдения, а не как артефакт, порождаемый телескопом.

Однако этого недостаточно, чтобы избежать ошибок, так как успех требует контроля над обстоятельствами таким образом, чтобы получить желаемый результат. Негативные артефакты существуют как возможности «сокрытых» вещей. Сокрытый объект существует как возможность, как и сам артефакт, который скрывает свою доступность, пока техническая модификация не задокументирует его существование в ходе испытания. Негативный артефакт тем самым формирует условия для актуализации вещи в условиях непредвиденных обстоятельств. Когда ошибки случаются, они рассматриваются как субъективные факторы, которые препятствуют тому, чтобы был показан объект сам по себе. Инструменты и приборы также имеют свои несовершенства, дефекты и связанные с ними погрешности. Таким образом, материальность научных практик, как будет показано далее, оказывает непосредственное влияние на производство научной объективности и наделяет эпистемическим статусом технологии, за счёт которых эта объективность производится.

СОВРЕМЕННЫЕ МЕДИЦИНСКИЕ ПРАКТИКИ: РАСПРЕДЕЛЁННАЯ АГЕНТНОСТЬ И ЭПИСТЕМИЧЕСКИЙ СТАТУС ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

Отказ от классической познавательной субъект-объектной модели отношений, который происходит в связи с «материальным поворотом» в исследованиях науки, приводит к сведению всех элементов исследовательского процесса и его результата (научного знания) к социальным характеристикам. «Забвение артефактов (в смысле вещей) означало создание другого артефакта (в смысле иллюзии): общество, которое должно поддерживаться только социальным» [7]. Получаемое знание определяется в своём содержании социальными процессами по его конструированию. Полученное знание — это готовый результат деятельности учёного. Однако если в классической науке оно обретало логическую форму в силу соответствия предмету изучения, то теперь оно становится научным результатом в силу его способности

успешно функционировать в обществе в качестве артефакта и при исключении из него всех следов социальной деятельности по его производству. Деятельность учёного (не столько как отстранённость от объекта исследования, сколько как специфическая форма субъективации в виде подчинения себя объекту, сопровождаемая при этом сопротивлением объекта подчиняться) создаёт научную бессубъектность: учёный — это судья над всегда существующим объектом, но не последняя инстанция, выносящая ему приговор. Хотя Б. Латур и заявляет, что «в науке нет такой вещи, как “орган, выносящий окончательные решения” (*res judicata*)» [8], тем не менее, по его собственным словам, всё же есть третья сторона принятия решения: независимый гибрид (который говорит от имени учёных, говорящих от имени «вещей»). Задача учёного не столько подчинить этот объект себе, сколько заставить его «говорить». Факты не говорят сами за себя, но в лаборатории они играют двоякую роль: с одной стороны, они представляют собой то, о чём говорят, а с другой — определяют истинность говоримого о них [8]⁷.

Для Латура наука — это не только дискурс: это, прежде всего, сеть практик по производству на свет фактов. В контексте понимания науки как технауки (когда техника и технологии начинают восприниматься не как приложение к науке, а как необходимый элемент её развития) ИИ наделяется особым эпистемическим статусом как неустрашимый из научной практики, в которой он применяется, агент (или актор). И в этой связи вопрос об инновациях в науке в эпоху цифровизации тесным образом связан с вопросом о том, как изменяется научная самость: что должен сделать с собой учёный, чтобы заниматься наукой, и что происходит с объективностью как эпистемической добродетелью сегодня? К концу XX века кажущиеся самоочевидными ранее способы репрезентации природы отошли на второй план с появлением новых технологий и нового гибридизированного способа делать науку. Соединение природного и артефактного в научной практике создания изображений как инструментов, обладающих размерностью атома, приводит от репрезентативной к презентативной стратегии⁸. Развитие нанотехнологий в XX–XXI вв. позволяет Дастон и Галисону ввести в оборот описание нового режима научной визуализации

⁷ Мир права и мир науки неслучайно оказываются столь тесно связанными: их объединяет общая добродетель, в качестве которой выдвигается беспристрастный подход, обеспечиваемый дистанцированностью и точностью. Каждая из областей использует собственный язык и способ мышления. Так, например, Латур предлагает рассмотреть Государственный Совет как лабораторию в поисках той объективности, которую преследуют учёные. Правительственный советник напоминает учёного тем, что «он говорит и публикуется от своего собственного имени; и, точно так же, что-то от правительственного советника есть в каждом учёном, рассматривающем себя как просветителя. Фигура правительственного советника, таким образом, представляет собой причудливый и сложный гибрид: в ней чувствуется что-то от суверенности (*lex animata*, закона, воплощённого в отдельном человеке; однако в рассматриваемом нами случае только сам данный человек этим законом и связан. <...> Правительственный советник — самый специфический пример инстанции, призванной производить возражения, производя тем самым объективность» [8]. Общий корень правовой и научной деятельности — искусство манипуляции с текстами и записями в целом.

⁸ Этот переход характеризуется следующим положением дел: «с одной стороны, есть прежние атласы, стремящиеся посредством репрезентации добиться верности природе. Корректный перенос природы на страницу мог пониматься как следование идее истины-по-природе (XVIII век), но также как приверженность механической объективности (XIX век) или тренированному суждению (XX век). С другой стороны, есть новейшие формы галерей изображений, являющиеся презентациями. Презентационная стратегия может соотноситься либо с новыми

«образ-как-инструмент». Соответственно, современные научные изображения становятся не столько отображением репрезентируемого объекта, сколько инструментом, позволяющим производить с ним манипуляции⁹. И в этом смысле наиболее глубокое изменение, демонстрирующее различие между репрезентативной и презентативной стратегиями, происходит именно на уровне научной самости: «учёный и инженер, являвшиеся по меньшей мере в этом гибридном поле отчётливо отличающимися друг от друга характерами, начали разнообразными способами утрачивать эту разницу. <...> Когда инженерно-научная самость начинает стабилизироваться, это происходит одновременно с выработкой нового отношения к образам. Они становятся инструментами, частью аппаратуры, напоминающими скорее экран компьютера, который показывает работу удалённо контролируемой роботизированной манипуляции в дистанционной хирургии, изменение траектории спутника в космосе, смешивание токсичных химикатов или обезвреживание бомбы» [1]. Стремление к минимизации роли самости¹⁰ в процессе создания и наблюдения объективного образа вплоть до отказа от самости как таковой, способной каким-либо образом вмешаться или неправильно увидеть и проинтерпретировать наблюдаемое явление, всё больше можно видеть в современных научных практиках, использующих технологии на основе ИИ. В этой связи резонным кажется вопрос о том, не грозят ли новые технологии стиранию научной самости как инстанции, которая была призвана регулироваться объективностью как эпистемической добродетелью. Не являемся ли мы свидетелями появления новых эпистемических режимов, разрывающих связь

этики и эпистемологии, или же носителями эпистемических добродетелей становятся алгоритмы, пришедшие на смену научным самостям?

Так, например, тип научной самости, определяемый как «объективный» учёный, — это фигура дисциплинированного осторожного наблюдателя, не вмешивающегося в процесс, а только беспристрастно фиксирующего наблюдаемые явления и правильно интерпретирующего их. Быть объективным (то есть придерживаться эпистемической добродетели объективности) значило не просто заниматься наукой, но, прежде всего, усмирять свою волю и самость, например, воздерживаясь от ретуширования фотографии. В этом смысле смена эпистемических добродетелей — это не столько смена научных практик, сколько смена этических установок, регулирующих поведение учёного. Однако, как отмечают Дастон и Галисон, «все эти три добродетели каждая на свой лад служили одной общей цели — тому, что мы называем верной репрезентацией природы» [1]. В связи с тем, что к концу XX в. кажущиеся самоочевидными ранее способы репрезентации природы отошли на второй план с появлением новых технологий, научная самость также трансформируется и радикальным образом расширяется¹¹, беря во внимание нейросети и технологии на основе ИИ как неустрашимый агент при принятии решения.

Поскольку визуальные представления в науке всё больше переплетаются с компьютерными и вычислительными форматами, их цифровая материальность требует особого подхода¹². И если ещё недавно, на рубеже XX–XXI вв., присутствие учёного-наблюдателя рассматривалось как некое явление, которое в будущем должно быть

типами вещей (пересобранные нанотрубки, нити ДНК или диоды), либо со свойственной презентациям заносчивой склонностью к тому, чтобы намеренно улучшать изображения с целью разъяснения, убеждения, доставления удовольствия, а иногда — продажи» [1]. Выделяя эти две стратегии — репрезентационную и презентационную — Дастон и Галисон, как отмечает О.Е. Столярова, неявным образом создают онтологию «коллективного становления» [9], эпистемологической импликацией которой будет, используя терминологию Я. Хакинга, не представление как воспроизведение уже существующего, а вмешательство как производство нового. Здесь мы имеем дело с конструктивизмом, истолкованным в прагматическом ключе: «вторая природа» накладывает онтологические рамки на наши теорию и практику. В современной эпистемологии изменяется понимание субъекта: на смену бестелесному субъекту приходит воплощённый субъект. Продуктом взаимодействия телесного субъекта с миром теперь становятся не субъективные образы объективной действительности, а артефакты, расширяющие, по Латуре, наши возможности и связи с другими людьми, социальными группами, изменяя тем самым и наши потребности.

⁹ Способность современных учёных манипулировать нанообъектами и их нанообразами сама по себе поразительна. Однако не менее удивительным представляется и тот факт, что «будучи произведёнными с помощью атомно-силового микроскопа, измеряющего силу между крошечным зондом и поверхностью сканирования, эти картинки не предназначены для того, чтобы изображать “природные” явления. Наоборот, эти и подобные им тактильные образы — неотъемлемая часть самого процесса изготовления» [1].

¹⁰ Стоит, однако, отметить, что стремление к минимизации самости, помимо того, что связано со стремлением минимизировать субъективность и, соответственно, ошибки, связанные с человеческим фактором, тем не менее «также избавляет врачей от выполнения части рутинных операций. Ещё одним существенным плюсом в использовании ИИ в медицине является снижение временных и материальных расходов» [10].

¹¹ Так, например, наблюдение и визуализация с использованием цифровых атласов мозга выстраивается в основном за монитором компьютера [11]. Это подразумевает изменение отношений между наблюдателем, объектом наблюдения, технологиями, используемыми для этой цели, и институциональными механизмами, обеспечивающими практику наблюдения. Цифровой атлас — в отличие от атласов, рассматриваемых Дастон и Галисоном, — приобретает черты инструмента не столько репрезентирующего, сколько презентующего, поскольку он одновременно может и представлять, и использоваться для совершенствования представлений.

¹² Так, например, результат сканирования мозга не является моментальным снимком, и ряд допущений Дастон и Галисона, связанных с реализмом в отношении механической объективности, не подходит для изображений сканированного мозга [11]. Благодаря развитию компьютерных технологий сканирование мозга стало встроенным в цифровой и сетевой контекст, что делает эту процедуру не столько репрезентативной, сколько презентативной.

устранено путём совершенствования алгоритмов и возможностей обработки изображений без человеческого вмешательства, то сейчас создание новых (по сравнению с предыдущими методами картографирования мозга) цифровых атласов выдвигает новые требования к контролю и ограничениям самости в достижении так называемой цифровой объективности¹³ [12]. Цифровые сканы помещаются в сложную инфраструктуру, которая обеспечивает визуальное знание способом, резко отличающимся от простой оценки механически полученных объективных представлений наблюдателем. Помимо объективного требуется некий реляционный взгляд, с помощью которого изображение рассматривается как набор данных по отношению к исследуемому объекту. Большие данные, накапливаемые в научных практиках, хотя и стремятся дать детальную и исчерпывающую картину представлений данных, но тем не менее дают только выборочное отражение значимой информации, что определяется во многом используемыми технологиями и платформами сбора данных, а также, что не менее важно, — онтологическими установками в отношении используемых данных. Иными словами, данные предполагают избирательный взгляд, настроенный определённым образом и ограниченный использованием определённых инструментов [13].

Новые методы их анализа (разработка новых способов управления данными на основе машинного обучения, компьютерного зрения и новых способов визуализации) знаменуют собой инновации, изменяющие современные научные исследования. Например, в нанонауке позиции почти отсутствуют, потому что она ориентирована на создание и изучение новых явлений и, следовательно, на особый вид визуализации, который их фиксирует. Однако простого ответа на вопрос, возникает ли в этом случае новый способ представления, нет: могут возникнуть сомнения относительно того, насколько новым является такой способ. Тем не менее не вызывает сомнений, что в нанотехнологиях и некоторых других развивающихся научных областях сходство с реальным объектом исследования больше не является доминирующим требованием к исследуемому объекту. Наряду с механической объективностью, достигаемой технологиями сканирования и визуализации, цифровые атласы «формируются за счёт привлечения компьютеризированных статистических

и количественных приборов, обеспечивающих дальнейший механизм утверждения и гарантии объективности» [12]. Предположение в обоих этих случаях состоит в том, что цифровая обработка изображений может способствовать эпистемическому идеалу объективности посредством развёртывания автоматизированных процессов, что, соответственно, уменьшает необходимость вмешательства в обработку данных.

В конечном счёте эпистемическая добродетель объективности, исторически сформированная как идеал научности, может быть в пределе замещена как научная ценность другой эпистемической добродетелью, образованной в результате тенденции ко всё большему сближению артефакта с образом, который становится уже не столько визуальным, сколько инструментальным. Научное видение становится неотделимым от производства визуального образа. Современный сдвиг от репрезентации к презентации становится поворотным в истории визуальных практик и объективности, подчёркивая сопряжение репрезентативных практик с процессом их конструирования: точность фотографических снимков не делегирует технологиям объективность, понимаемую как стремление к минимизации субъективности¹⁴.

Внедрение технологий на основе ИИ и компьютерного зрения призвано стандартизировать потоки изображений, направленных на первичное и автоматизированное выявление дефектов, патологий, масштабирование программ скрининга и пр. Так, например, разработанный сервис для анализа биомедицинских изображений имеет целью научное исследование возможности использования в системе здравоохранения города Москвы методов поддержки принятия решений на основе результатов анализа данных с ИИ¹⁵. Сервис помимо прочего направлен на минимизацию рисков появления ошибки в диагностике, однако это не исключает и появления ложноположительных результатов. При этом фигура врача как «эксперта» не устраняется из процесса диагностики, но дополняется фигурой «ИИ» и гибридной фигурой «ИИ + Эксперт». Объективность врача при принятии решения будет во многом опираться на анализ тех данных, которые он получил от сервиса. Однако для получения результата первичной диагностики экспертного заключения врача не требуется: оно может понадобиться только на следующем этапе

¹³ В 1990-е гг., в «десятилетие мозга», был создан ряд цифровых и электронных ресурсов, позволяющих рационализировать и интегрировать различные области нейробиологии. Этот подход был описан как «нейроинформатика». В ходе совершенствования атласов мозга то, что составляло объективное нейробиологическое знание, переосмыслилось в соответствии как с возможностями, заложенными в новые технологии, так и с ограничениями стандартизации, присущими проектам, включающим множество измерений. Понятие «цифровая объективность» предлагается в качестве обозначения конкретной конфигурации идеалов, методов и объектов познания в современной кибернауке [12].

¹⁴ Так, например, Р. Буани описывает случаи, в которых техника не способна распознать значимые различия, в связи с чем исследователям приходится буквально дорисовывать элементы снимков, выделять их и структурировать [14].

¹⁵ Исследование реализуется в трёх проектах: «Эксперимент по использованию инновационных технологий в области компьютерного зрения для анализа медицинских изображений и дальнейшего применения в системе здравоохранения города Москвы»; HUB — ИИ-консультант врача (сервис автоматического анализа рентгенологических исследований для врачей); «Технологии распознавания речи в здравоохранении» — технология автоматического преобразования устной речи в текст, основанная на алгоритмах ИИ, с помощью которой врач может управлять рабочей станцией голосовыми командами и диктовать описание исследования вместо того, чтобы набирать его вручную [15].

в случае, если результаты ИИ окажутся неудовлетворительными: алгоритмы компьютерного зрения, как указано, проанализируют снимки пациентов, и только при необходимости эти результаты будут проверены опытными экспертами (рис. 1, 2).

ЭТИЧЕСКИЕ ВЫЗОВЫ: ПЛЮСЫ И МИНУСЫ СУБЪЕКТНОСТИ И СУБЪЕКТИВНОСТИ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

Роботизированные аппараты на основе ИИ уже оказывают существенную поддержку как медикам, так и самим

пациентам в диагностике, терапии, хирургии. В России уже есть роботизированные медицинские комплексы — например, робот-хирург AST (Assisted Surgical Technologies)¹⁶. В терапии традиционно именно терапевт как врач первичного звена ставит предварительный диагноз. Однако роботы уже перенимают на себя его функции: всю информацию могут собрать специальные датчики, расположенные на теле пациента, и в случае обнаружения патологии передать информацию врачу. Система способна провести и саму диагностику вместо врача. Российский диагностический комплекс RoboScan проводит ультразвуковое сканирование в автоматизированном режиме.

Грамотное использование нейросетей в медицинских практиках (например, в целях выявления



Рис. 1. Скриншот страницы проекта телемедицинской платформы врачей с описанием процесса исследования.




Рис. 2. Скриншот страницы проекта телемедицинской платформы врачей с описанием предоставляемых сервисов.

¹⁶ <https://new.fips.ru/registers-doc-view/fipservlet?DB=RUPAT&DocNumber=2715400&TypeFile=html> [дата обращения 09.02.2024].

ковидного поражения лёгких) позволяет снизить дозу рентгеновского излучения для томографии, поскольку такая предварительно обученная модель нейронной сети выступает в некотором роде уже в качестве эксперта¹⁷. Таким образом, работа по сбору данных и проведению первичной диагностики, а в некоторых случаях и по представлению предварительного решения, стандартизирована и формализована, что должно способствовать большей объективности. Это, с одной стороны, позволяет снизить нагрузку на врачей как на экспертов, позволяя им сосредоточиться на изучении и интерпретации данных, их описании и формировании заключений. Врачи передают ИИ всё больше своих обязанностей, а также ответственность за обработку данных, диагностику, разработку способов лечения, налаживание взаимодействия с пациентом и в том числе за принятие решения. С другой стороны, это естественным образом ставит вопрос о том, как скоро ИИ сможет в таком случае заменить врача полностью, и с какими этическими вызовами в этой связи уже сейчас нам предстоит столкнуться на этом пути.

В случае неправильной постановки диагноза или выявления патологии, что повлечёт за собой соответствующие последствия, кто будет ответственным субъектом принятия решения? В России в одной из первых стран в мире сформулированы риски и угрозы (включённые в «Кодекс этики ИИ» [17] как угрозы правам и свободам человека), которые может повлечь за собой цифровизация и применение технологий на основе ИИ в сфере медицины: дискриминация, потеря приватности, потеря контроля над ИИ, причинение вреда человеку ошибками, допущенными алгоритмами ИИ, применение ИИ в неприемлемых целях. Так, например, недавно Росздравнадзор приостановил применение системы для анализа снимков компьютерной томографии с использованием ИИ Botkin.AI «в связи с угрозой причинения вреда жизни и здоровью граждан»¹⁸.

Принятие решений сегодня уже не является прерогативой человека-эксперта: эта функция передаётся

интеллектуальным системам. Создание природоподобной техносферы невозможно без передачи права принимать решение техническим системам, поэтому в ближайшие 10–20 лет этот тренд будет только продолжаться¹⁹. Цифровая трансформация современной медицины происходит в том числе и на коммуникативном уровне, «на котором врач и больной могут оказаться дистанцированы друг от друга с помощью технических барьеров. С другой стороны, цифровые технологии порождают феномен расширенного сетевого пространства, где резко возрастают возможности сближения и преодоления существующих границ (в частности, географических) между врачами и пациентами. В нём также возникает возможность замещения и вытеснения эксперта-врача с его традиционной профессиональной ниши, но вместе с тем появляются возможности формирования сетевого коллективного экспертного субъекта (цифровые лаборатории и консилиумы врачей)» [19].

«Тенденция замещения и отчасти вытеснения экспертных функций врача квазиэкспертизой, осуществляемой с помощью цифровых технологий, также свидетельствует о новой форме выстраивания коммуникации — от взаимоотношений эксперта (профессионала в области медицины) и профана (неспециалиста-пациента) к гибридной модели «врач + программа-пациент» и в отдалённой перспективе к коммуникативной модели «программа-пациент», лишаящей эксперта (врача) статуса носителя абсолютного (или приближенного к абсолютному) знания и наделяющей этим правом цифровую программу. Последняя модель является техноцентричной, но в определённом смысле она становится и пациентоцентричной, нивелируя роль врача» [19]. Делегирование технологиям экспертной функции демонстрирует общую тенденцию на освобождение от диагностических ошибок врача, и чем точнее ИИ справляется с определением патологии или рисков развития заболевания, тем выше стремление к замещению экспертных функций алгоритмами и тем ярче претензия системы поддержки принятия решений уже не просто на роль инструмента

¹⁷ «Предлагаемый способ позволяет уменьшить общее количество рентгеновских проекций, необходимых для выявления COVID-19, и, таким образом, снизить дозу облучения без значительного снижения точности прогнозирования. Предлагаемый протокол был оценён на 163 пациентах из набора данных COVID-CTset, обеспечив среднее снижение дозы на 15,1%, в то время как среднее снижение точности прогнозирования составило всего 1,9%, достигнув улучшения оптимальности по Парето по сравнению с фиксированным протоколом» [16].

¹⁸ <https://www.kommersant.ru/doc/6350252> [дата обращения 09.02.2024].

¹⁹ Крупных исследований, касающихся опроса мнений врачей и пациентов относительно их отношения к внедрению ИИ в медицинские практики, пока нет. Тем не менее в недавнем исследовании общественного мнения, проводимом впервые среди врачей с целью оценки их заинтересованности в использовании ИИ в области медицины и здравоохранения и выявления проблем и перспектив внедрения ИИ, был сделан достаточно оптимистичный вывод: «российские врачи выступают за ИИ в медицине. Большинство респондентов считают, что ИИ не заменит их в будущем и станет полезным инструментом. В первую очередь, для оптимизации организационных процессов, исследований и диагностики заболеваний». При этом отмечается, что «среди возможных проблем при использовании ИИ отметили отсутствие гибкости и ограниченное применение по спорным вопросам (64% и 60% респондентов). 56% считают, что принятие решений с использованием ИИ будет затруднено, если для анализа будет представлена неадекватная информация. Треть врачей опасаются, что в разработке ИИ принимали участие специалисты с небольшим опытом, а 89% респондентов считают, что врачи должны участвовать в разработке ИИ для медицины и здравоохранения. Только 20 участников (6,6%) ответили, что согласны с тем, что ИИ может заменить их на работе. В то же время 76% респондентов считают, что в будущем врачи, использующие ИИ, заменят тех, кто этого не делает» [18].

человеческого целеполагания, но на роль полноценного актора, выполняющего сложнейшие манипуляции, что «приводит к неактуальности и излишеству человеческого взгляда, с его ошибками, искажёнными оценками, неизлечимой пристрастностью. Технике предоставляют выносить суждения о картине реальности, с которой она сталкивается» [19]. В таком случае можно предположить, что если сохранится тенденция на ограничение самости в пользу передачи этой самости в конечном счёте ИИ, то мы неизбежно в самом ближайшем будущем должны будем перестать относиться к технологиям на основе ИИ как к инструменту и принять во внимание их полноценную субъектность и субъективность, со всеми плюсами и минусами.

СПИСОК ЛИТЕРАТУРЫ

1. Дастон Л., Галисон П. Объективность / под ред. К.В. Иванова. Москва: Новое литературное обозрение, 2018. EDN: PIXKTY
2. Мол А. Множественное тело: Онтология в медицинской практике / под ред. С.М. Гавриленко, А.А. Писарева. Пермь: Гиле Пресс, 2017. EDN: LJXRPN
3. Daston L., Galison P. The Image of Objectivity // *Representations*. 1992. N 40. P. 81–128. doi: 10.2307/2928741
4. Масланов Е.В. Артефакт: культура и природа. В: Эпистемология сегодня. Идеи, проблемы, дискуссии / под ред. И.Т. Касавина, Д.А. Алексеевой, А.Ю. Антоновского, и др. Н. Новгород: Национальный исследовательский Нижегородский государственный госуниверситет им. Н.И. Лобачевского, 2018. С. 295–299. EDN: ELYPTC
5. Бейкер Л.Р. Онтологическая значимость артефактов. В: Онтологии артефактов: взаимодействие «естественных» и «искусственных» компонентов жизненного мира / под ред. О.Е. Столяровой. Москва: Издательский дом «Дело» РАНХиГС, 2012. С. 18–33.
6. Lynch M. Art and Artifact in Laboratory Science: A Study of Shop Work and Shop Talk in a Research Laboratory. London/Boston/Melbourne: Routledge & Kegan Paul, 1985.
7. Латур Б., Вахштайн В., Смирнов А. Об интеробъективности // *Социологическое обозрение*. 2007. Т. 6, № 2. С. 79–96. EDN: JWURYH
8. Латур Б. Научные объекты и правовая объективность // *Культиватор*. 2011. № 2. С. 74–95.
9. Столярова О.Е. Исторический контекст науки: материальная культура и онтологии // *Эпистемология и философия науки*. 2011. Т. 30, № 4. С. 32–50. EDN: OPDQIX
10. Алексеева М.Г., Зубов А.И., Новиков М.Ю. Искусственный интеллект в медицине // *Международный научно-исследовательский журнал*. 2022. № 7 (121). С. 10–13. EDN: JMMMDf doi: 10.23670/IRJ.2022.121.7.038
11. Beaulieu A., de Rijcke S. Networked Neuroscience: Brain Scans and Visual Knowing at the Intersection of Atlases and

ДОПОЛНИТЕЛЬНАЯ ИНФОРМАЦИЯ

Источник финансирования. Автор заявляет об отсутствии внешнего финансирования при проведении исследования.

Конфликт интересов. Автор декларирует отсутствие явных и потенциальных конфликтов интересов, связанных с публикацией настоящей статьи.

ADDITIONAL INFORMATION

Funding source. This article was not supported by any external sources of funding.

Competing interests. The author declares that she has no competing interests.

Databases. Coopmans C., Woolgar S., editors. In: Representation in Scientific Practice Revisited. Coopmans C., Vertesi J., Lynch M., Woolgar S., editors. Cambridge: MIT Press, 2014. P. 131–152. doi: 10.7551/mitpress/9780262525381.003.0007

12. Beaulieu A. Voxels in the Brain: Neuroscience, Informatics and Changing Notions of Objectivity // *Social Studies of Science*. 2001. Vol. 31, N 5. P. 635–680. doi: 10.1177/030631201031005001

13. Китчин Р. Большие данные, новые эпистемологии и смена парадигм // *Социология: методология, методы, математическое моделирование*. 2017. № 44. С. 111–152. EDN: YMAFTQ

14. Buiani R. Innovation and Compliance in Making and Perceiving the Scientific Visualization of Viruses. *Canadian Journal of Communication*. 2014. Vol. 39, N 4. P. 539–556. doi: 10.22230/cjc.2014v39n4a2738

15. Центр диагностики и телемедицины [Internet]. Москва: c2013-2023 [дата обращения: 29.11.2023]. Доступ по ссылке: <https://mosmed.ai/>

16. Bulatov K.B., Ingacheva A.S., Gilmanov M.I., et al. Reducing radiation dose for NN-based COVID-19 detection in helical chest CT using real-time monitored reconstruction // *Expert Systems with Applications*. 2023. Vol. 229 Part A. doi: 10.1016/j.eswa.2023.120425

17. Кодекс этики в сфере ИИ [Internet]. AI Alliance Russia, c2020-2024 [дата обращения: 09.02.2024]. Доступ по ссылке: <https://ethics.a-ai.ru/>

18. Orlova I.A., Akopyan Zh.A., Plisyuk A.G., et al. Opinion research among Russian Physicians on the application of technologies using artificial intelligence in the field of medicine and health care // *BMC Health Services Research*. 2023. Vol. 23, N 1. P. 749. doi: 10.1186/s12913-023-09493-6

19. Попова О.В. Цифровизация и трансформация медицины: проблемы и перспективы развития. В: Современные проблемы социо-техно-антропосферы: коллективная монография / под ред. В.Г. Буданова. Курск: Университетская книга, 2022. С. 153–171.

REFERENCES

1. Daston L, Galison P. *Objectivity*. Ivanov KV, editor. Moscow: Novoe literaturnoe obozrenie; 2018. (In Russ). EDN: PIXKTY
2. Mol A. *The body multiple ontology in medical practice*. Gavrilenko SM, Pisarev AA, editors. Perm: Gile Press; 2017. EDN: LJXRPN
3. Daston L, Galison P. The Image of Objectivity. *Representations*. 1992;(40):81–128. doi: 10.2307/2928741
4. Maslanov EV. Artifact: culture and nature. In: *Epistemology today. ideas, problems, discussions*. Kasavin IT, Alekseeva DA, Antonovskii AYU, et al, editors. N. Novgorod: Lobachevsky State University of Nizhni Novgorod; 2018. P:295–299. EDN: ELYPTC
5. Baker LR. Ontological significance of artifacts. In: *Ontologies of artifacts: the interaction of "natural" and "artificial" components of the lifeworld*. Stolyarova OE, editor. Moscow: Izdatel'skii Dom «Delo» RANKhiGS; 2012. P:18–33. (In Russ).
6. Lynch M. *Art and Artifact in Laboratory Science: A Study of Shop Work and Shop Talk in a Research Laboratory*. London/Boston/Melbourne: Routledge & Kegan Paul; 1985.
7. Latour B, Vakhshstein V, Smirnov A. On interobjectivity. *Russian sociological review*. 2007;6(2):79–96. (In Russ). EDN: JWURYH
8. Latour B. Scientific objects and legal objectivity. *Kul'tivator*. 2011;(2):74–95. (In Russ).
9. Stolyarova OE. The historical context of science: material culture and ontologies. *Epistemology and philosophy of science*. 2011;30(4):32–50. (In Russ). EDN: OPDQIX
10. Alekseeva MG, Zubov AI, Novikov MYu. Artificial intelligence in medicine. *International Research Journal*. 2022;(7(121)):10–13. EDN: JMMMDf doi: 10.23670/IRJ.2022.121.7.038
11. Beaulieu A, de Rijcke S. Networked Neuroscience: Brain Scans and Visual Knowing at the Intersection of Atlases and Databases. Coopmans C, Woolgar S, editors. In: *Representation in Scientific Practice Revisited*. Coopmans C, Vertesi J, Lynch M, Woolgar S, editors. Cambridge: MIT Press; 2014. P:131–152. doi: 10.7551/mitpress/9780262525381.003.0007
12. Beaulieu A. Voxels in the Brain: Neuroscience, Informatics and Changing Notions of Objectivity. *Social Studies of Science*. 2001;31(5):635–680. doi: 10.1177/030631201031005001
13. Kitchin R. Big data, new epistemologies and paradigm shifts. *Sociology: methodology, methods, mathematical modeling (4M)*. 2017;(44):111–152. EDN: YMAFTQ
14. Buiani R. Innovation and Compliance in Making and Perceiving the Scientific Visualization of Viruses. *Canadian Journal of Communication*. 2014;39(4):539–556. doi: 10.22230/cjc.2014v39n4a2738
15. Center for diagnostics and telemedicine [Internet]. Moscow; c2013–2023 [cited 2023 Nov 29]. Available from: <https://mosmed.ai/>
16. Bulatov KB, Ingacheva AS, Gilmanov MI, et al. Reducing radiation dose for NN-based COVID-19 detection in helical chest CT using real-time monitored reconstruction. *Expert Systems with Applications*. 2023;229 Part A. doi: 10.1016/j.eswa.2023.120425
17. AI ethics code [Internet]. AI Alliance Russia, c2020–2024 [cited 2024 Feb 9]. Available from: <https://ethics.a-ai.ru/>
18. Orlova IA, Akopyan ZhA, Plisyuk AG, et al. Opinion research among Russian Physicians on the application of technologies using artificial intelligence in the field of medicine and health care. *BMC Health Services Research*. 2023;23(1):749. doi: 10.1186/s12913-023-09493-6
19. Popova OV. Digitalization and transformation of medicine: problems and prospects for development. In: *Modern problems of socio-technical-anthroposphere: a collective monograph*. Budanov VG, editor. Kursk: Universitetskaya kniga; 2022. P:153–171. (In Russ).

ОБ АВТОРЕ

Баева Ангелина Викторовна, канд. философ. наук;
адрес: Россия, 119192, Москва,
Ломоносовский проспект, д. 27, к. 4;
ORCID: 0009-0005-5871-6217;
eLibrary SPIN: 2951-1427;
e-mail: a-baeva93@mail.ru

AUTHOR'S INFO

Angelina V. Baeva, Cand. Sci. (Philosophy);
address: 27-4 Lomonosovsky Prospekt,
119192, Moscow, Russia;
ORCID: 0009-0005-5871-6217;
eLibrary SPIN: 2951-1427;
e-mail: a-baeva93@mail.ru