



MOSCOW CENTER
FOR DIAGNOSTICS & TELEMEDICINE

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

DIGITAL DIAGNOSTICS

A peer-reviewed scientific medical journal

5 Volume 1 Issue

Artificial intelligence in medicine

2024



ECO • VECTOR

<https://jdigitaldiagnostics.com>

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. Ome'lyanovskiy, 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

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

Гомбелевский 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».



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. Yazovskih, 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

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. Синицын, 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

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>

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>

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1920×969×24BPP。图像类别数量为12个。为了创建训练和验证数据集，对1100×550×24BPP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

论证

光学相干断层扫描是一种检测视网膜和玻璃体视网膜前层病变的现代高科技信息方法[1]。然而，对研究结果的描述和解释需要医生的高素质和特殊培训，还需要眼科医生和患者花费大量时间。因此，迫切需要解决与光学相干断层扫描图片分类过程自动化相关的问题。

与此同时，目前计算机工具和技术发展迅速，可以在各种架构的神经网络基础上创建人工智能系统，既有医疗系统[2, 3]，也有通用系统[4-6]。过去几十年来，现代眼科中心建立了病人数据存储库，其中包括数以万计或数十万计的光学相干断层扫描图片，这为寻找各个参数之间的广义依赖和关系开辟了道路，也为构建基于科学方法（其核心几乎总是数学模型）的全新识别、分类、计算和预测方法开辟了道路。

在我们的一项研究中，我们已经介绍了使用人工神经网络进行玻璃体分析、视网膜边缘提取和近似、边缘曲率确定、视网膜平均厚度计算等的计算机方法[7]。本文是这项工作的逻辑延续，介绍了使用卷积神经网络对光学相干断层扫描图片进行分类时，使用单模型和多模型方法所取得的结果。

值得注意的是，已出版的一些研究都致力于解决类似问题。因此，Yu. A. Vasiliev等人[8]开发了一种通用方法，用于测试和监控基于人工智能技术的医疗诊断软件。该方法旨在提高该软件的质量及其在实际医疗中的应用。它包括七个阶段：自我测试、功能测试、校准测试、技术监测、临床监测、反馈和改进。该方法的一个显著特点是对软件进行循环测试、监测和改进，从而不断提高其质量，同时对其工作成果提出详细要求，并让医生参与评估。该方法使软件开发人员能够在各个领域取得优异成绩并展示成就，也使用户能够在经过独立和全面质量保证的程序中做出明智和自信的选择。

E. A. Katalevskaya等人的文章[9]旨在开发用于在眼底数码相机照片上分割糖尿病视网膜病变和糖尿病黄斑水肿视觉征象的算法。他们选择了国际分类中包含的征象进行分割：微动脉瘤、硬性渗出物、软性渗出物、视网膜内出血、视网膜和视盘新生血管、视网膜前出血、视网膜上纤维化、激光凝固剂。使用TensorFlow深度学习框架（Google Brain, 美国）实现并训练了神经网络。训练数据库的大小为1200张照片，而验证数据库则使用了310张眼底照片。训练模型的准确率为86%至96%。

在T. Kepp等人的研究[10]描述了一套用于家庭监测老年黄斑变性的系统。这里使用卷积神经网络对整个视网膜以及色素上皮脱落进行分割。整个数据集包括711幅图像，按60%:20%:20%的比例分为训练/验证/测试三部分。结果表明了，基于卷积神经网络的方法能相当准确地分割视网膜。

S. N. Sakhnov等人[11]的目的是基于一个开放数据集开发一个白内障筛查模型，并在临床数据上进行验证。开放数据集包括使用智能手机摄像头获取的9668张图像，其中4514张属于白内障类别，5154张属于健康眼睛。外部验证集包含51幅白内障和正常图像。卷积神经网络被用来创建机器学习模型。内部验证集的数据分类准确率为97%，外部验证集为75%。作者认为预测值较低，并认为需要对模型进行微调，以提供必要的性能指标水平。

S. V. Shukhaev等人[12]使用预先训练好的网络ResNet-18、ResNet-50、VGG16、VGG19和GoogleNet来解决卷积神经网络在自动检测Fuchs内皮营养不良症中的适用性问题。使用Tomey EM-3000内皮显微镜（Tomey Corporation, 日本）获得的角膜生物显微镜图像被随机抽样（ $n=700$ ）。在第一阶段，图像被分为两组。第一组包括存在Fuchs内皮营养不良症的图像，第二组包括正常或其他病变的图像。内皮细胞密度图像分为三类：训练数据集、验证数据集和测试数据集。在测试样本上验证神经网络后，不同卷积神经网络架构的F指标值如下：ResNet-18——0.985；ResNet-50——1.000；VGG16——0.940；VGG19——0.990；GoogleNet——0.987。在使用冻结层、Adam优化器和交叉熵作为损失函数的ImageNet数据上，ResNet-50显示出最佳结果。

因此，通过对上述作品的简要分析，我们可以得出结论，基于卷积神经网络的人工神经网络模型有望用于解决光学相干断层扫描视网膜图片分类问题。

目的

使用Google Colaboratory中的Python Keras和Tensorflow库，开发基于深度学习卷积神经网络的光学相干断层扫描图片分类数学（计算机）模型架构。比较使用单模型和多模型方法对光学相干断层扫描图片进行分类的计算实验结果，并估算此类分类的准确率。从分类准确率和所使用的超参数值的角度，对人工神经网络模型的最佳架构得出结论。

材料和方法

原始数据集代表了真实患者的匿名光学相干断层扫描图片，包括直接从DRI OCT Triton光学相干断层扫描仪（Topcon Corporation, 日本）获取的1004幅图像，分辨率为 $1920 \times 969 \times 24$ BPP，为JPG文件。整个数据集由经验丰富的眼科专家根据分类目标分为12类：

- 1、正常；
- 2、黄斑囊样水肿；
- 3、神经上皮层脱落；
- 4、色素上皮脱落；
- 5、硬性渗出物；

- 6、视网膜上纤维化;
- 7、玻璃体黄斑粘连;
- 8、玻璃体后脱离;
- 9、穿透性黄斑劈裂+视网膜上纤维化;
- 10、硬性渗出物+黄斑囊样水肿;
- 11、色素上皮疣;
- 12、未穿透性黄斑劈裂+视网膜上纤维化。

每类图片的数量与患者相应病变的发生频率相对应。在随后的计算实验中,该数据集又增加了新的光学相干断层扫描图片,因此图片总数超过了2000张。为了创建训练、验证和测试数据集,从整幅图像中“切割”出 $1100 \times 550 \times 24$ BPP的靶向区域。计算实验中的整个数据集一般分为三部分:训练/验证/测试,比例为70%:20%:10%。

还使用了以下技术:

- 使用NEAREST、BILINEAR、BICUBIC、LANCZOS滤波器调整图片大小(rescale);
- 数据增强(data augmentation),即使用各种选项进行增强:按指定角度旋转图片、在X和Y方向移动图像、水平和垂直旋转、改变图片通道的亮度。

值得注意的是,最简单的NEAREST滤波器考虑最近像素的参数,在我们研究中其效果最好。而使用不同方法对区域进行近似处理的更复杂滤波器则显示出最差的结果。显然,这是由于在平滑过程中丢失了对分类很重要的图像小细节。

编制模型时使用了以下参数:

- Adam优化器:最有效的优化算法之一;
- categorical_crossentropy损失函数:分类交叉熵;
- accuracy指标:算法的正确答案比例。

需要注意的是,如果各组在图片数量上是平衡的,通常会使用accuracy指标来解决分类问题。在我们的案例中,由于训练样本和测试样本中的图片数量较少,因此决定采用总体平均分。

所有模型工作流程均使用Google Colaboratory中的Python语言工具进行。

结果

初步计算实验

在初步的计算实验中,我们评估了不同方法(如使用预训练网络和迁移学习的能力)、图像大小调整和增强技术以及人工神经网络模型超参数组合(卷积层和全连接层的数量、数据包大小等)对光学相干断层扫描图片分类的有效性。

对于基于MobileNetV2和MobileNetV3的预训练神经网络,训练样本的准确率为95-98%,验证样本的准确率为61-80%,测试样本的准确率为41-59%。使用工具将图片缩放至 224×224 像素大小,以实现与MobileNet的匹配。

我们还比较了不同预训练神经网络在指定数据集上的迁移学习可学性。验证结果如下: MobileNetV2为80%, ResNet101V2为81%, InceptionResNetV2为79%, NASNetLarge为80%。

对于采用传统架构的多层卷积神经网络(几个卷积Conv2D层,每个层都有MaxPooling2D子样功能,数组转换为一维Flatten张量,以及多个全连接Dense层),在合理选择Epoch数的情况下,训练样本的准确率可达70%-100%。然而,在验证样本上,这一数字要低得多,而且变化较大(35%-94%)。在两种情况下,验证准确率高于训练时显示的准确率,这可能是由于训练和验证样本存在显著的异质性。在测试中,准确率更低,只有27-59%,这当然不能被认为是令人满意的结果。

初步实验得出以下结论:

- 训练样本不平衡、不均匀,需要修正和用新图片进行补充;
- 虽然迁移学习模型的分类结果稍稍好一点,但这些结果仍不足以在眼科实践中使用,而且由于第一隐藏层的“冻结”,改进的余地不大;
- 要达到可接受的分类准确率,需要优化超参数,可能还需要优化分类方法本身。

计算实验:单模型方法

考虑到初步实验所获得的结果,我们在数据集中添加了新的光学相干断层扫描图片,因此图片总数超过了2000张。在实验过程中,我们测试了多层序列卷积神经网络的不同架构:几个卷积Conv2D层,每个层的输出都有一个MaxPooling2D子样本层,以及一个转换为一维Flatten张量的层和两个全连接Dense层。后者有一个softmax神经元传递函数,便于完成分类任务。

对于 512×512 像素的归一化图片分辨率(所有数据集图片均使用rescale工具缩放至该分辨率),卷积层的极限数量为7。我们测试了层数从2到7的卷积神经网络结构(表1),同时选择了层中滤波器的大小和数量。我们对所有计算实验进行了训练(通常使用epochs=15、数据包大小BATCH_SIZE=50、编译参数optimiser='adam'、loss='categorical_crossentropy'、metrics=['accuracy']),并对之前未包含在数据集中的图片进行了验证和额外测试。

除两层模型外,几乎所有人工神经网络模型都达到了可接受的训练和验证准确率(见表1)。不过,如果我们比较一下它们通过附加测试的准确率,则会发现随着卷积层数的增加,准确率首先会上升,六层模型的最高值为85%,而七层模型的准确率则会下降。需要指出的是,本文介绍的模型目前仅定位为眼科医生的决策支持系统。考虑到数据集仅包含数量有限的各种病理图像,我们认为85%的准确率对于经验不足的眼科医生进行图像分类来说是足够和合适的。结论是,就准确率而言,有一个最佳的层数,在本例中为6层。不过,随着数据集中新数据的积累和模型的重新训练,这一数值还可以进一步改变。

卷积层数从4到7的人工神经网络模型的训练和验证过程见图1。当使用4和5个卷积层时,训练过程在9个Epoch后完成,训练和验证的准确率达

表1. 人工神经网络不同序列模型的比较

卷积层数	需要优化的参 数数量	训练准确 率, %	验证准确 率, %	附加测试的准确 率, %	备注
2	31 844 921	13	0	0	人工神经网络模型训练不足
3	13 401 045	97	100	55	人工神经网络模型的训练Epoch数: 超过 15。 卷积神经网络层中的滤波器数量: 3/8/16
3	15 215 889	100	100	62	人工神经网络模型的训练Epoch数: 9。 卷积神经网络层中的滤波器数量: 4/8/16
3	13 401 933	100	100	64	人工神经网络模型的训练Epoch数: 12。 卷积神经网络层中的滤波器数量: 5/8/16
4	6 929 729	100	100	65	人工神经网络模型的训练Epoch数: 12
5	1 430 977	100	100	70	人工神经网络模型的训练Epoch数: 9
6	556 673	100	100	85	人工神经网络模型的训练Epoch数: 15
7	132 801	100	89	74	人工神经网络模型的训练Epoch数: 超过15
8	-	-	-	-	对于可接受的图像尺寸, 无法使用8层卷 积神经网络




图1. 卷积神经网络模型的训练和验证: *a*——四个卷积层; *b*——五个卷积层; *c*——六个卷积层; *d*——七个卷积层。

到100%。与此同时，附加测试的准确率仅为65–70%（见表1）。对于有6个卷积层的模型，训练过程需要更长的时间，即15个Epoch，训练和验证的准确率也达到了100%。不过，通过附加测试的准确率提高到了85%，我们认为这是一个令人满意的结果。当卷积层数进一步增加到7层时，人工神经网络模型的训练和验证过程需要超过15个Epoch，训练准确率为100%，验证和测试准确率分别下降到89%和74%（见图1和表1）。

视网膜光学相干断层扫描图片分类准确率方面的最佳人工神经网络模型结构见图2。它包括6个带有MaxPooling2D子样的卷积Conv2D层、一个Flatten层和两个作为分类器的全连接Dense层，其中最后一个层具有softmax神经元传递函数。

测试分类准确率较低（与训练和验证相比）的原因如下。在进行模型训练时，使用的数据集相对较小，约有2000张图像，这些图像很可能不包含特定病理特征的全套图形细节。如果测试样本中出现此类细节，即使在人工神经网络模型验证过程中获得了100%的准确率，分类结果也可能是不正确的。

初步计算实验：多模型方法

根据这项研究的一般逻辑，并考虑到必须提高通过附加测试的准确率，O. L. Fabrikantov和E. V. Kulagina提出了一个顺序方案，大致模拟了眼科医生识别视网膜光学相干断层扫描图片的过程。在此基础上建立了计算机算法（见图3）。

该算法采用多模型顺序实施原则（图3）。

在第一阶段，对图像进行初步处理（第1–3块）。第4块使用人工神经网络模型1进行初步分类：区分正常与病态。分类结果被存储（S1）。

该模型必须经过训练，并在仅包含两类相关图像的特殊数据集1上进行验证。如果没有检测到病变（第5块），我们绕过所有中间阶段，进入第四阶段：玻璃体分析。同样，在第6块：我们使用在特殊数据集2上训练的人工神经网络模型2来检测是否存在黄斑劈裂。结果被存储（S2）。如果存在黄斑劈裂（第7块），第8块使用同样在特殊数据集3上训练的人工神经网络模型3来确定黄斑劈裂是穿透性劈裂还是未穿透性劈裂，然后将结果存储起来（S3），并进入第二阶段。

如果没有黄斑劈裂（第7块），则进入第9块，在此块中，在特殊数据集4上训练的人工神经网络模型4检测出三种变体的一种，即黄斑囊样水肿、弥漫性黄斑水肿或没有黄斑水肿。结果被存储（S4），然后进入第二阶段。

在第二阶段，借助在特殊数据集5上训练的人工神经网络模型5（第10块），检测出三种变体的一种，即神经上皮层脱落、色素上皮脱落或不存在上述变体，然后结果被存储（S5），进入第三阶段的光学相干断层扫描图片分析和分类。

第三阶段是依次使用人工神经网络模型6、7和8。

- 对人工神经网络模型6（第11块）在特殊数据集6上进行训练，以区分是否存在视网膜上纤维化。
- 对人工神经网络模型7（第12块）在特殊数据集7上进行训练，以区分是否存在色素上皮疣。
- 对人工神经网络模型8（第13块）在特殊数据集8上进行训练，以区分是否存在渗出物。

```
[ ] 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')
])
```

图2。具有六个卷积层的人工神经网络模型的结构和参数。Conv2D中的第一位数字是卷积层中使用的滤波器数量，接下来的两位数字是以像素为单位的滤波器大小。网络中神经元的激活函数为relu，输出分类层的激活函数为softmax。全连接Dense层的第一位数字是神经元数量。




图3。用于识别光学相干断层扫描图片的多模型算法流程图。

在第11-13块中，还将相应的结果存储起来（S6、S7、S8），然后进入第四阶段。

第四阶段是神经网络模型9（第14块）在特殊数据集9上进行训练，以区分正常、玻璃体后脱离、玻璃体黄斑粘连和玻璃体黄斑牵引。结果被储存（S9）。第15块和第16块根据先前储存的S1-S9形成病理总清单，并将带有光学相干断层扫描图片描述的报告输出到文件中。

讨论

在所述方法中，使用了9个不同的人工神经网络模型（每个模型都在各自独特的数据集（1-9）上经过训练）来对光学相干断层扫描图片进行病理分类。需要注意的是，在玻璃体分析的最后阶段，可以使用我们之前介绍的算法[7]来代替神经网络模型9。它包括以下内容：

- 垂直扫描图像，确定玻璃体边界的X坐标和Y坐标；
- 使用移动平均法平滑Y坐标，其基点与最小图像细节（在我们的案例中为10像素）可公约数，用适当阶数的样条线或抛物线逼近玻璃体边界；
- 计算边界的最大曲率和相应距离，以确定玻璃体后脱离、玻璃体黄斑粘连和玻璃体黄斑牵引。

目前我们正在测试多模型算法（见图3），同时增加数据集中光学相干断层扫描图片的数量，并优化神经网络模型的超参数。对该算法的几个阶段进行的初步计算实验表明了，训练和验证的准确率有可能达到98-100%，同时由于每个阶段分类的因子数量减少，通过额外测试的准确率比单模型方法有所提高。所有神经网络模型1-9都使用相同的7个卷积层结构。唯一不同的

是，它们是在独特的数据集上训练的，因此神经元突触连接的系数集也不同。

结论

提出的是视网膜光学相干断层扫描图片分类的单模型和多模型原则。使用不同的人工神经网络模型架构对从DRI OCT Triton光学相干断层扫描仪获得的此类图片进行自动分类的计算实验表明了，在训练和验证期间的准确率为100%，在附加测试中的准确率为85%，这是一个令人满意的结果。

我们选择了最佳的人工神经网络模型结构（6层卷积神经网络），并确定了其超参数值。在这种情况下，眼科领域的决策支持系统的发展得以应用。

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.

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. *Sovremennye 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

A.A. 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.

for medical diagnostics. *Digital Diagnostics*. 2023;4(3):252–267. doi: 10.17816/DD321971

9. Katalenskaya EA, Katalensky 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, Pustozero 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

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., Владзимирский А.В., Омелянская О.В., и др. Методология тестирования и мониторинга программного обеспечения 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

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

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

* Corresponding author / Автор, ответственный за переписку

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>

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>

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. Vladimirov命名的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

论证

据世界卫生组织统计,全球约有22亿人患有视力障碍,其中大部分患者年龄超过50岁[1]。黄斑疾病,尤其是老年性黄斑变性和糖尿病性黄斑水肿,在造成不可逆失明和低视力的原因中占很大比例[2]。

截至2020年,全球共有1.96亿老年性黄斑变性患者,预计2040年这一数字将达到2.88亿[3]。在临床上,老年性黄斑变性可表现为疣沉积、视网膜色素上皮变化、黄斑新生血管、渗出和出血。晚期会出现视网膜色素上皮的地理萎缩[4]。这些疾病表现会导致明显的视力障碍。

糖尿病患者的人数正在稳步增加。与此同时,这种疾病的视力表现也在增加。据预测,到2045年,糖尿病视网膜病变病例数将增至1.605亿,其中危及视力的糖尿病视网膜病变患者人数将达到4482万[5]。发生在糖尿病视网膜病变不同阶段的糖尿病性黄斑水肿是糖尿病患者视力丧失的最常见原因,美国每年新增近75千名患者[6]。糖尿病性黄斑水肿的发病率与糖尿病视网膜病变的严重程度直接相关,其中70%发生在增殖期。在1型糖尿病患者中,27%的人在发病后9年内患上糖尿病性黄斑水肿[7]。在俄罗斯,有超过63万名不同阶段的糖尿病视网膜病变患者,在1型糖尿病患者中,其发病率是两倍[8]。

中心性浆液性脉络膜视网膜病变在危及视力的黄斑疾病中排名第四,其特点是神经上皮发生浆液性脱落,发生在脉络膜毛细血管浸润区。研究报告显示,中心性浆液性脉络膜视网膜病变的发病率为每10万人有9.9例。这一过程通常是单侧的,但也有40%的病例会出现双侧病变[9]。5%的病例会出现慢性病变,30%–50%的患者会在12个月内复发中心性浆液性脉络膜视网膜病变[10]。

玻璃体黄斑界面异常包括黄穿透性黄斑劈裂和未穿透性黄斑劈裂、玻璃体黄斑牵引和黄斑前膜。在某些情况下,玻璃体黄斑界面的变化可能不会导致明显的功能障碍,但如果对黄斑区造成严重影响,则会出现伴随明显视力障碍的症状,并对患者的生活质量造成负面影响。黄斑劈裂的发病率为每1000名55岁以上的患者中有3.3例[11]。根据不同作者的研究,年发病率从每10万人中有4.71例到8.5例不等[12]。

BDES (the Beaver Dam Eye Study) 使用光学相干断层扫描进行了一项为期20年的随访,发现黄斑前膜的发病率为34.1%。尽管这种疾病的发病机制不同,但临床表现可能相同。黄斑前膜可能是一种特发性疾病,也可能是在既往眼科疾病(如糖尿病视网膜病变、视网膜静脉闭塞或既往白内障手术)背景下出现的并发症[13]。出现黄斑前膜而无玻璃体后脱离,容易形成黄斑水肿和切线牵引综合征导致的未穿透性黄斑劈裂[14]。

如今,随着人口预期寿命的延长,及早发现随年龄增长而发展的疾病显得尤为重要。众所周知,及时发现疾病对治疗起着重要作用,也是降低发病率的主要步骤之一。由于糖尿病性黄斑水肿和老年性黄斑变性仍然是导致视力下降的主要原因,因此有必要对这些病症进行定期眼科筛查,以确定需要接受专门眼科治疗的患者。这种策略可以在早期阶段防止失明的发生[15]。及时开始治疗往往是取得良好疗效的关键,可获得积极的形态和功能结果(主要是视力)。

血管内皮生长因子抗体(anti-VEGF)疗法是治疗新生血管性老年性黄斑变性和糖尿病性黄斑水肿的金标准[16]。迄今为止,治疗这些疾病的方案多种多样。所有提议的方案都使用根据临床研究和光学相干断层扫描数据对治疗进行的评估,需要定期进行评估。目前,光学相干断层扫描是信息量最大、应用最广泛的视网膜病理诊断方法,可在治疗过程中提供准确的监测。光学相干断层扫描数据不仅可用于评估黄斑区的现状,也可用于选择特定病例所需的治疗策略。

需要定期进行眼科检查的黄斑疾病患者人数不断增加,给医疗系统造成了切实的负担。要在有限的时间内对大量患者进行诊断、评估所获得的数据并确定治疗策略,需要大量的人力和时间资源,这可能会造成医疗资源不足。要解决这一问题,就必须开发眼科图像分析的创新方法并将其引入临床实践,同时使用人工智能技术[17]。

得益于人工智能方法的发展,现在整个领域都在开发和实施医生活动中的智能系统。俄罗斯已经批准了2030年前的国家人工智能发展战略¹。

在俄罗斯和世界范围内,创建和验证临床实践中诊断视网膜病变的人工智能程序的工作正在进行中。来自Google DeepMind (英国、美国)的项目作者对32家眼科诊所临床实践中获取的大量图像进行了研究,这些图像涵盖了不同的人群。图像诊断的结果可用于量化视网膜形态并得出特定病变的测量值。该公司的软件能够高效地对扫描进行分流,其效率甚至超过了专科医生。论文作者对国家方向的53种病症进行了研究。根据他们的结论,他们提出的新系统能够定性、高效地分析临床光学相干断层扫描图像并提出建议。今后,他们计划关注更多的临床病理,并扩大工作范围。

在U.Schmidt-Erfurth教授的指导下,维也纳大学(奥地利)的工作人员开发了RetInSight程序,旨在利用人工智能算法监测新生血管性老年性黄斑变性治疗的效果。该方案基于视网膜内液和视网膜下液以及视网膜色素上皮脱落的分割原理,并对上述结构的体积进行动态评估[18]。

总部位于芝加哥的Altris Inc. (美国)宣布推出用于自动分析光学相干断层扫描的Altris AI软件。根据开发商提供的数据,该平台可对100

¹ 俄罗斯联邦总统于2019年10月10日第490号命令《关于俄罗斯联邦人工智能发展》。访问方式: <http://www.kremlin.ru/acts/bank/44731>。

种病理和病理征兆（包括罕见病理和病理征兆）进行快速分析和可视化。装入的算法能够诊断青光眼、老年性黄斑变性、糖尿病视网膜病变和其他视网膜疾病。用户可使用筛查、分割/分类和报告模块[19]。

在B. E. Malyugin等人的研究[21]中，他们关注的是创建一种算法，用于自动检测老年性黄斑变性患者血管内皮生长因子抗体疗效的生物标志物。他们确定了七种生物标志物：色素上皮脱落、色素上皮、视网膜下积液、视网膜内积液、椭圆体区、视网膜神经纤维层和视网膜下高反射信号物质。视网膜色素上皮脱落的Dice指数为0.8，视网膜色素上皮和视网膜下积液为.4，其他生物标志物为0.3至0.15。今后，计划扩大训练数据集，提高工作的准确率[20]。

目的

研究基于结构性光学相干断层扫描的人工智能程序在诊断黄斑病变方面的能力。

材料与方法

研究设计

用于研究的结构性光学相干断层扫描图片是通过RTVue XR 110-2眼科光学相干断层成像仪（Optovue，美国）获取的。为了分析光学相干断层扫描图片，研究人员使用了基于人工智能算法Retina.AI的数字医学图像处理软件（Digital Vision Solutions LLC，俄罗斯）。该研究采用非劣效性设计，是一项单中心回顾性观察随机非对照试验。

纳排标准

纳入标准：

- 曾诊断出糖尿病性黄斑水肿、老年性黄斑变性（干性和渗出性）、中心性浆液性脉络膜视网膜病变、玻璃体黄斑牵引综合征（玻璃体黄斑牵引、黄斑前膜、穿透性和非穿透性黄斑劈裂）；
- 中心视力下降，怀疑黄斑病变。

排除标准：

- 由于光学介质的透明度明显受损（角膜混浊、成熟白内障、眼前房出血、玻璃体出血等）而无法进行光学相干断层扫描检查；
- 无法固定患者的视线（眼球震颤、帕金森症等）。

分组分析

这项研究包括129名患者，平均年龄为65.9岁。女人占总人数的55.8%（72名患者），男人占44.2%（57名患者）。共有200只眼睛接受了检查，病症如下：

- 糖尿病性黄斑水肿；
- 黄斑囊样水肿；
- 老年性黄斑变性（黄斑新生血管、视网膜疣）；
- 中心性浆液性脉络膜视网膜病变；

表1。按病名分类的受检眼睛分布情况

诊断	眼睛数量
糖尿病性黄斑水肿/黄斑囊样水肿	52
老年性黄斑变性：黄斑新生血管	41
老年性黄斑变性：视网膜疣	40
中心性浆液性脉络膜视网膜病变	25
玻璃体黄斑牵引综合征	25
穿透性黄斑劈裂	23
非穿透性黄斑劈裂	25
黄斑前膜	72
无病变	34

- 玻璃体黄斑牵引综合征；
- 穿透性黄斑劈裂；
- 非穿透性黄斑劈裂；
- 黄斑前膜。

没有黄斑病变的眼睛也接受了检查。表1列出了按病名分类的分布情况。

执行条件

在本研究中，对在俄罗斯联邦国家预算机构《联邦医疗和生物局联邦专门医疗和医疗技术研究与临床中心》以及莫斯科州国家预算卫生机构《以M.F.Vladimirov命名的莫斯科州临床研究所》接受检查和治疗的患者的结构性光学相干断层扫描图片进行了临床对比分析。研究为期12个月。

医疗干预措施描述和主要研究结果

人工智能程序对结构性光学相干断层扫描图片的分析分两个阶段进行。在第一阶段，程序对生物标志物进行分割。在第二阶段，程序使用鉴别诊断搜索算法计算出可能的病理结果。人工智能程序在对光学相干断层扫描图片进行分析时得出的结论与两名眼科医生的临床报告数据进行了比较。

伦理审查

俄罗斯联邦国家预算机构《联邦医疗和生物局联邦专门医疗和医疗技术研究与临床中心》伦理委员会，2022年11月29日第11_2022号会议记录摘录2。结论：“根据的TU 58.29.32-001-60003594-2022，批准在俄罗斯联邦国家预算机构《联邦医疗和生物局联邦专门医疗和医疗技术研究与临床中心》使用通过分析眼底照片和结构性光学相干断层扫描图片诊断眼科病症的数字医学图像工作软件Retina.AI，对从医疗数据库中选取的患者眼底照片和光学相干断层扫描图片进行回顾性分析”。

结果登记方法。统计分析

为了评估该方案的准确率，计算了以下参数：

- 真正例数——TP (True positives)；
- 假正例数——FP (False positives)；

- 假反例数——FN (False negatives);
- 真反例数——TN (True negatives)。

根据所提供的参数,使用以下公式计算出了每个病名的灵敏度、特异性和准确率得分:

Precision (准确率)——在预测的正例中,真

正例所占比例:
$$\text{Precision} = \frac{TP}{(TP + FP)}$$

Recall/Sensitivity (灵敏度)——在所有正例

中,正确预测的正例所占比例:
$$\text{Recall} = \frac{TP}{(TP + FN)}$$

Specificity (特异性)——在所有反例中,正确

预测的反例所占比例:
$$\text{Specificity} = \frac{TN}{(TN + FP)}$$
 [17]。

结果

研究对象 (参与者)。主要研究成果

研究对象是通过分析结构性光学相干断层扫描图片诊断眼科病症的数字医学图像工作软件,即 Retina.AI。研究以评估和分析临床数据的形式进行,没有患者参与。

在使用该软件分析光学相干断层扫描图片时,确定了以下病理结构:

- 视网膜内囊肿、视网膜下积液;
- 视网膜色素上皮脱落;
- 视网膜下高反射信号物质;
- 视网膜疣;
- 黄斑前膜;
- 玻璃体黄斑牵引;
- 穿透性黄斑劈裂;
- 非穿透性黄斑劈裂。

根据检测到的病理迹象,程序自动得出结论。该方法的一般指标如下:灵敏度为95.16%;特异性为97.76%;准确率为97.38%。表2列出了人工智能程序和眼科医生结论的详细对比分析结果。

图1给出的是患者B的黄斑区结构性光学相干断层扫描图片,54岁,患有2型糖尿病。根据眼科医生的报告,诊断结果为“糖尿病性黄斑水肿”。Retina.AI人

工智能算法在对结构性光学相干断层扫描图片进行程序分析的过程中,发现了以下病理迹象:视网膜内囊肿、视网膜下积液。结论诊断为糖尿病性黄斑水肿。

图2给出的是患者V的黄斑区结构性光学相干断层扫描图片,68岁,患有渗出性老年性黄斑变性。诊断由眼科医生确定。Retina.AI人工智能算法在对结构性光学相干断层扫描图片进行程序分析的过程中,发现了以下病理迹象:视网膜内囊肿、视网膜下积液、视网膜色素上皮脱落、视网膜下高反射信号物质。根据程序报告,记录了黄斑新生血管。

图3给出的是患者K的黄斑区结构性光学相干断层扫描图片,69岁,眼科医生诊断为“穿透性黄斑劈裂”。Retina.AI人工智能算法在对结构性光学相干断层扫描图片进行程序分析的过程中,确定了以下病理结构:穿透性黄斑劈裂、视网膜内囊肿、黄斑前膜。根据程序报告的数据,诊断出了穿透性黄斑劈裂和黄斑前膜。

不良事件

研究过程中未发生任何不良事件。

讨论

主要研究成果概述

在临床试验中,基于Retina.AI算法的软件在黄斑病理诊断中表现出极高的灵敏度、特异性和准确率:除玻璃体黄斑牵引综合征的灵敏度为86.96%外,所有疾病的诊断率均超过90%。该软件的优点是用户界面方便,可以在光学相干断层扫描图片中突出显示检测到的病理结构,这让医生有机会仔细检查程序的正确性,增强医生对人工智能技术的信心。

对主要研究成果的讨论

从实际应用的角度来看,在筛查检查中的应用是将人工智能技术引入临床工作的最有前途的领域之一,因为此时需要对大量病人进行检查,并确定哪些病人需要接受专门的眼科治疗。人工智能技术为将部分职能委托给护理人员 and 组织院前筛查提供可能性,以便医生腾出时间处理更复杂的任务,并提高眼

表2。Retina.AI诊断黄斑疾病的灵敏度、特异性和准确率

诊断	灵敏度, %	特异性, %	准确率, %
糖尿病性黄斑水肿/黄斑囊样水肿	96.08	97.48	97.14
黄斑新生血管	97.50	97.65	97.62
老年性黄斑变性: 视网膜疣	97.37	96.51	96.67
中心性浆液性脉络膜视网膜病变	92.59	98.36	97.62
玻璃体黄斑牵引	86.96	97.33	96.19
穿透性黄斑劈裂	95.65	98.40	98.10
黄斑前膜	100.00	97.12	98.10
非穿透性黄斑劈裂	95.83	97.85	97.62
无病变	94.72	97.69	97.25




图1。人工智能程序分析一名糖尿病性黄斑水肿患者黄斑区结构性光学相干断层扫描图片的实例：*a*——结构性光学相干断层扫描图片；*b*——对病理结构进行分割后的结构性光学相干断层扫描图片（视网膜下积液：绿色掩模，视网膜内囊肿：蓝色掩模）；*c*——扫描图片分析结果报告（在鉴别诊断搜索表中，糖尿病性黄斑水肿作为一种可能的病理用红色标出）。




图2。人工智能程序分析一名渗出性老年性黄斑变性患者黄斑区结构性光学相干断层扫描图片的实例：*a*——结构性光学相干断层扫描图片；*b*——对病理结构进行分割后的结构性光学相干断层扫描图片（视网膜下积液——绿色掩模，视网膜内囊肿——蓝色掩模，视网膜色素上皮脱落——橙色掩模，视网膜下高反射信号物质——黄色掩模）；*c*——扫描图片分析结果报告（在鉴别诊断检索表中，黄斑新生血管作为可能的病理用红色标出）。

科诊室的通过能力。但需要强调的是，人工智能技术不能替代眼科医生，只能作为提高治疗和诊断效率的工具。由于平台位于“云空间”，因此必须使用稳定的互联网连接，这可能会给人工智能程序的实施带来一定的困难。为了在连续模式下方便地工作，开发一个不依赖于设备上互联网可用性的桌面应用程序是很有前途的。

治疗过程中的病理过程筛查是另一个利用人工智能技术的有前途领域。通过对视网膜内囊肿、视网膜下积液、色素上皮脱落和视网膜下高反射信号物质进行分割，可以定量评估糖尿病性黄斑水肿和渗出性老年性黄斑变性患者在血管内皮生长因子抗体治疗期间这些结构体积的动态变化。迄今为止，医生在治疗过程中使用的主要定量指标是光学相干断层扫描血管




图3。人工智能软件分析一名被诊断为黄斑劈裂、黄斑前膜患者的黄斑区结构性光学相干断层扫描扫描图片的实例：*a*——结构性光学相干断层扫描图片；*b*——对病理结构进行分割后的结构性光学相干断层扫描图片（穿透性黄斑劈裂——紫色掩模，视网膜内囊肿——蓝色掩模，黄斑前膜——红色掩模）；*c*——扫描图片分析结果报告（在鉴别诊断搜索表中，黄斑前膜、穿透性黄斑劈裂作为可能的病理用红色标出）。

造影显示的老年性黄斑变性患者最大矫正视力、视网膜中部厚度和新生血管膜面积。为评估血管内皮生长因子抗体疗效开发新的定量标准是眼科医生和人工智能算法开发人员共同努力的一项紧迫任务。

使用我们技术的一些局限性在于，只能对加载到程序中的单个光学相干断层扫描图片进行评估。当务之急是改进软件，以便将来能对一名患者的全系列图片进行分析。

结论

基于人工智能算法的Retina.AI软件在临床验证过程中，在对结构性光学相干断层扫描图片的分析基础上，在诊断糖尿病性黄斑水肿、干性和渗出性老年性黄斑变性、中心性浆液性脉络膜视网膜病变和玻璃体黄斑界面异常方面表现出较高的灵敏度、特异性和准确率。Retina.AI平台是俄罗斯开发的，目前可在以下链接进行测试：www.screenretina.ru。值得注意的是，该程序的结论不是诊断，需要专家的澄清。

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

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.

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, Fayzrahmanov 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

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/OPTH.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. Малюгин Б.Э., Сахнов С.Н., Аксенова Л.Е., и др. Разработка модели глубокого машинного обучения для обнаружения биомаркёров 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

AUTHORS' INFO

*** Margarita R. Khabazova;**

address: 28 Orekhovy 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

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

* Corresponding author / Автор, ответственный за переписку

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>

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>

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

论证

世界卫生组织指出，心血管疾病及相关病症是导致死亡的主要原因之一[1]。其中包括被称为“无声杀手”的主动脉瘤。它们通常在无症状的情况下形成，可导致血管夹层或破裂，94%-100%的病例会导致患者死亡[2, 3]。有关胸主动脉瘤发病率统计分析的研究非常少[4]。在俄罗斯，根据各种数据，升主动脉瘤的发病率为0.16-1.06%。值得注意的是，俄罗斯上一次对胸主动脉瘤发病率进行大规模流行病学研究是在大约40年前[5]，这证实了新研究的相关性。

根据以O.M.Filatov命名的第15市临床医院（莫斯科）在十年间进行的尸检结果，有0.8%的病例证实死因是胸主动脉瘤，其中只有11%的病例在死前曾怀疑有动脉瘤[4]。在美国，主动脉瘤在心血管疾病死亡率结构中排名第17位。在美国，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每10万人1.6例[6]。在瑞典，胸主动脉瘤和夹层的发生率高达每10万人16.3例[7]。根据耶鲁大学的数据，在已报告的病例中，动脉瘤破裂的年发生率高达3.6%，夹层的发生率高达3.7%[8]。

使用胸部计算机断层扫描（CT）筛查肺部恶性肿瘤时，在50岁以上的患者中发现胸主动脉病理性扩张的频率高达8.1%[9, 10]。

机会性筛查是一种对定向研究进行前瞻性和回顾性分析的方法，可发现定向研究以外的其他病理和风险因素。这种方法避免重复研究，有助于减轻患者的辐射负担[11]。

2022年，莫斯科进行了超过584千次胸部CT检查，未使用造影剂。这样的检查量代表了对各种病症进行机会性检测的潜力，包括胸主动脉扩张（增宽、动脉瘤）这一危及生命的病症[12]。

世界上规模最大的关于人工智能技术应用效果和质量评估的研究，即《使用创新计算机视觉技术进行医学图像分析并进一步应用于莫斯科市医疗系统的实验》（以下简称“莫斯科实验”），自2020年起在莫斯科进行[13]。作为“莫斯科实验”的一部分，人工智能技术在莫斯科市卫生局《诊断和远程医疗技术科学实践临床中心》专家的监督下以测试模式使用。这一过程包括对系统质量的持续评估和对其功能的调整，对准确性指标进行计算，确定响应误差和其他特征。因此，为回顾性研究以及放射科医生在初级分析期间处理放射学数据创造了条件。

目的

评估人工智能技术在利用胸部CT数据检测胸主动脉瘤方面的有效性，并分析将人工智能技术用作放射科医生医疗决策支持系统的可能性，以便对放射检查进行初步描述。

材料和方法

研究设计

该研究对自动化莫斯科统一医疗信息系统的统一放射信息服务“统一医疗信息分析系统”（EMIAS）在2022年6月1日至2022年11月30日期间通过人工智能技术处理的84405份胸部CT结果进行了回顾性分析。研究设计见图1。从总计84405名18岁以上患者样本中，使用这些人工智能技术筛选出86名疑似胸主动脉瘤且最大直径超过50mm的患者（由莫斯科N.V.Sklifosovsky紧急医学研究所的血管外科医生进行筛选）。




图1。研究设计。

此外,两名具有5年以上经验的放射科医生(来自诊断和远程医疗技术科学实践临床中心)对获得的样本进行了重新检查。如果前两位放射科医生的意见不一致,则由拥有10年放射科经验的专家担任仲裁人,就是否存在动脉瘤及其描述的措辞做出最终决定。

在审查过程中,有1 名患者被排除在外:6例是由于统一放射信息服务中没有放射科医生的初步协议,5例是由于人工智能技术的数据处理结果(评估非靶向病理或器官),这些研究被归类为假阳性。最终样本包括75名转诊进行后续检查和治疗的患者。

此外,还从84405个检查中随机抽取了1000个,以评估主动脉直径的年龄分布。由于患者年龄数据缺失而排除了32个病例,样本量为968个检查(男性433例,女性535例,分别占44.7%和55.3%)。

纳入标准

在“胸主动脉瘤”莫斯科实验框架内使用人工智能技术对样本进行分析的胸部CT检查的纳入标准:

- 莫斯科市卫生局门诊和住院医疗机构的患者(女生和男生)(年龄在18岁以上);
- 进行的检查:胸部CT,无造影剂增强,切片厚度 $\leq 3\text{mm}$;
- 提供DICOM格式的胸部CT图像和统一放射信息服务EMIAS中的放射科医生报告。

排除标准:

- 在胸腔器官区域存在金属结构(术后缝合线、钢板)形成伪影的患者,包括心脏起搏器;
- 存在造影剂增强和肺内核检查;
- 没有DICOM格式的CT图像和/或统一放射信息服务EMIAS中的放射科医生报告。

执行条件

人工智能技术根据被称为“基本诊断要求”的规则处理检查,以确定胸主动脉的病理扩张。这些规则是根据欧洲心脏病学会关于主动脉疾病诊断和治疗的建议制定的[14]:

- 升主动脉扩张:40至49mm;
- 升主动脉瘤: $\geq 50\text{mm}$;
- 降主动脉瘤: $\geq 40\text{mm}$ [15]。

为了自动测定胸主动脉直径,采用了国内人工智能技术算法“Chest-IRA”(IRA Labs,俄罗斯)。在莫斯科实验框架内,对该人工智能技术的准确率进行了评估,结果如下:

- ROC曲线下面积(AUC)——0.99;
- 灵敏度——0.94;
- 特异性——0.96;
- 准确率——0.95;
- 分析时间(一个检查)——2.1分钟[16]。

图2给出利用人工智能技术算法操作的示例。

两名放射科医生(有5年以上经验)、一名放射科专家和一名血管外科医生(有10年以上经验)对所有75例样本中疑似胸主动脉瘤(最大直径大于50mm)的CT检查进行了回顾性验证。人工智能技术的正确性是通过测量胸主动脉的轴向投影来验证的。医生根据欧洲心血管成像协会和欧洲心脏病学会工作组的建议[17],测量了胸主动脉的最大前后径和垂直径。样本中的所有患者都会被转诊接受后续检查,并在此基础上决定进一步的随访或治疗。

使用夏皮罗-威尔克检验法分析了患者组的正态分布。考虑到所有子样的分布与正常值存在差异($p < 0.001$),数据以“中位数[第25个百分点;第75个百分点];数值的最小值/最大值”的形式显示。组间比较采用Mann-Whitney检验。

结果

主要研究成果

使用人工智能算法处理了84405例无造影剂增强的胸部CT检查,以检测病理性胸主动脉扩张。放射科医生和血管外科医生从这些样本中挑选出86例(男性62例,女性24例)通过人工智能怀疑患有胸主动脉瘤的患者,对他们进行了回顾性评估。在这86个检




图2. 在处理胸部计算机断层扫描数据时使用人工智能综合服务的示例: **a**——人工智能技术正确识别并标记(红线)了胸主动脉瘤升支和降支的可疑部位; **b**——假阳性结果:纵隔肿块连同胸主动脉升支被标记(红线),胸主动脉降支的直径被标注在绿色框内。这项人工智能综合服务还包括标记肺部浸润性病变(橙色轮廓)和胸腔积液(黄色轮廓)的附加模块。

查中,有6个由于统一放射信息服务EMIAS中没有主要放射科医生的报告而被排除在样本之外。5个检查因人工智能处理结果(评估非靶向病理/器官,见图2, b)而出现假阳性,也被排除在样本之外。

最终样本包括75个检查:其中男性57例(66[59; 73]; 27-87岁),女性18例(62[59; 74]; 47-87岁)。44例(59%)患者的首次放射报告中描述了胸主动脉瘤,31例(41%)患者的首次报告中未发现动脉瘤。因此,使用人工智能可额外检测出31例胸主动脉瘤(41%)。在这组患者中,男性胸主动脉的最大直径为56[54; 60]; 52-84mm,女性为57[54; 63]; 52-87mm。

在胸部CT检查中通过人工智能检测到动脉瘤的患者会被告知并转诊接受明确检查(超声心动图、CT或磁共振血管造影、心脏病专家和/或血管外科医生会诊),以确定其随访和治疗方法。

在后续检查中还获得了其他信息:在75名患者中,有4名(5.33%)患者在诊断过程或手术干预完成前死亡,3名(4%)患者决定拒绝进一步的诊断检查和治疗。另有31名患者(41.33%)拒绝进行交流。

在37名继续接受观察和治疗的患者中,有25人(33.33%)在经过全面诊断检查后确诊为胸主动脉瘤(他们继续接受观察),12人(16%)被确诊为细化诊断(他们继续接受心脏病专家的治疗)。有3名患者在诊断检查后未确认动脉瘤的存在:他们被诊断为胸主动脉扩张。此外,由于存在动脉瘤,还进行了两次主动脉支架植入术。

通过人工智能检测到动脉瘤的男女组在年龄和胸主动脉最大直径方面没有明显差异($p>0.05$)。

研究第二部分的结果

我们还从84405个病例中随机抽取了968个检查样本,获得了动脉瘤发病率的初步数据(图3)。在成人(18岁及以上)人群中,胸主动脉扩张的发病率为14.5%,胸主动脉瘤的发病率为1.2%。

该组患者的年龄为:女性为65[51; 75] ($n=535$); 19-102岁,男性为60[47; 71] ($n=433$); 18-95岁。女性样本略大于男性样本,反映了所研究的患者总人数的性别分布情况。女性的年龄中位数(65岁)略高于男性(60岁),四分位数之间的范围相似。

该组患者的胸主动脉直径为:女性为34[31; 37]; 20-50mm,男性为36[33; 39]; 24-60mm。

根据年龄和胸主动脉最大直径的不同,男女组之间存在明显差异($p<0.001$)。

需要注意的是,男性和女性的胸主动脉直径与年龄有明显的相关性。男性胸主动脉直径与年龄有关的相对变化更为明显,为0.177mm/年,女性为0.118mm/年。

讨论

研究成果概要

对工作期间获得的数据进行的分析表明了,在主动脉瘤患者样本(75名患者)中,男性和女性群体在年龄和胸主动脉最大直径方面没有显著差异($p>0.05$)。同时,在968名患者样本中(从总体中随机抽取),男性和女性在年龄和胸主动脉最大直径方面存在显著差异($p<0.001$)。这说明有必要制定性别和年龄标准来描述年龄分布情况。为了更全面地分析已确定的模式,还需要进行更多专门设计的研究。

对研究成果的讨论

由于在回顾性研究中应用了人工智能算法,检测到的动脉瘤数量有所增加,这证实了在实践中使用这一解决方案的有效性和可行性:例如,作为放射科医生在初步描述放射检查时的辅助工具。不过,我们也注意到软件出现假阳性的现象。有一些方法可以通过监测和对算法的额外培训来尽量减少此类错误[20-22]。




图3. 在968个检查样本中,胸主动脉最大直径与年龄的关系图: a——男性; b——女性。

根据文献资料, 年龄与胸主动脉直径呈正相关。有研究指出, 男性的胸主动脉直径值高于女性[18], 而且男性和女性的胸主动脉直径依赖性更明显[19], 这与我们的研究得出的统计结果完全一致。

由于各种原因, 医生有可能遗漏有临床意义的病变: 职业倦怠 (如COVID-19大流行之后)、工作量增加、缺乏医务人员。这也是支持使用人工智能作为放射科医生分析胸部CT扫描时的医疗决策支持系统的另一个理由, 因为使用人工智能可以提高检测能力, 减少遗漏有临床意义病理的数量[23]。

我们使用的国内人工智能并非世界唯一, 质量指标可用于指导对人工智能的选择。国外也有类似的人工智能用于胸主动脉直径的自动测量和动脉瘤的检测, 有助于避免误差, 可用于机会性筛查[24, 25]。

根据文献, 人工智能有助于放射科医生减少在放射检查中检测病变的时间[26, 27]。

人工智能是一种很有前途的主动脉测量工具[28]。然而, 测量的准确性问题仍未解决, 需要进一步研究。这项研究表明, 人工智能不能取代医生, 但可以协助放射科医生, 告知主动脉可能存在的病变, 以避免错过临床上重要的异常情况。但需要注意的是, 放射科医生必须了解人工智能的工作原理以及在分析检查时可能出现的错误[29–33]。因此, 在医学中使用人工智能可能是检测胸主动脉瘤的重要工具。

在初始放射检查描述和回顾性研究中使用人工智能检测胸主动脉的病理扩张是合理的, 这样可以最大限度地减少可能遗漏的具有临床意义的病变。

结论

在初级胸部CT检查描述过程中使用人工智能并扩大机会性筛查的范围, 可提高对胸主动脉瘤

等临床重大病理情况的检出率, 避免对患者造成不良后果。进一步优化这类需要紧急医疗干预的患者的手术治疗路线是当务之急。最好能制定出胸主动脉直径的人群标准值, 以便调整该病症的诊断标准。

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. Vladzimyrskey — 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.

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, Ekborn 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: WSYSP
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, Vladzmyrskyy 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. Vladzmyrskyy 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/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;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, Petraiin 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, Vladzmyrskyy 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

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 расщелений 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 инцидентом. 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: WSYSP
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. Etlí 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., Кожикина Д.Д., и др. Эффективность применения технологий искусственного интеллекта 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., Туравилова 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., Владимирский 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: SYZAOQ doi: 10.25881/18110193_2023_2_16

AUTHORS' INFO

*** Alexander V. Solovlev;**

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. Vladzimirskyy, MD, Dr. Sci. (Medicine);

ORCID: 0000-0002-2990-7736;
eLibrary SPIN: 3602-7120;
e-mail: VladzimirskijAV@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

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

Владимирский Антон Вячеславович, д-р мед. наук;

ORCID: 0000-0002-2990-7736;
eLibrary SPIN: 3602-7120;
e-mail: VladzimirskijAV@zdrav.mos.ru

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

* Corresponding author / Автор, ответственный за переписку

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>

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>

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

论证

近年来,虚拟和模拟技术越来越多地应用于医疗活动的不同领域以及医学院的教学过程中。各种类型的真实过程模拟在许多领域的专家培训和工作中使用已有相当长的时间,其发展也已进行了几十年[1-3]。这一进程的加速,既是由于我们生活的普遍数字化,也是由于目前将这些技术直接应用于实际医学的积极引入。

虚拟仿真器和模拟器、增强现实工具越来越多地应用于诊所,不仅用于诊断检查,还用于外科手术、麻醉和复苏等领域的医疗实践。这些工具包括三维“解剖”台和可视化台、研究人体解剖的虚拟现实程序、手术模拟器和机器人等[4-6]。因此,在对医科大学毕业生和接受再培训的专家进行培训和知识控制的过程中,以及在国家认证和鉴定过程中,包括在“超声诊断”专业中,都开始使用数字化方法[1, 7]。人们对这类技术越来越感兴趣的另一个原因是,医学院和研究生培训机构近来在工作场所的诊所教授一些学科时面临越来越多的困难。

其中包括与门诊工作直接相关的困难:检查地点和时间的限制[7, 8]、超声波机的缺乏、导师的缺乏、检阅时进入科室的问题。另一部分困难则与实际受检者有关:学生在与患者初次接触时承受的心理压力、部分患者不愿意接受受训者的检查[8]、诊所缺乏必要病理的患者、所谓“疑难”患者的可视性差等。问题的第三部分是由学生自身的理论培训水平和工作过程中的活跃程度决定的,这可以大大增加练习必要技能的时间,而这在诊所中是有限的。此外,可以强调的一点是,由于正常和病理解剖知识不足,检查方法难以确定。首先,这是指正确定位探头,这可能需要很长时间,并给受试者造成不适。

在这方面,改变医科大学一些学科的教学方法和计划,将各种现代虚拟和模拟设备纳入其中,是一项紧迫而必要的任务。在培训放射诊断领域的专家时,这个问题尤为重要,因为他们长期以来一直在使用创建和处理数字图像的程序,并应掌握必要的技能和知识。

与此同时,在医学学科教学中使用此类技术的经验却相当匮乏。在这方面,国内外文献中专门论述这一主题的原创性著作寥寥无几。其中大多数都指出了在超声诊断专家培训中使用模拟技术的积极方面[7-10],但也存在一些不足,特别是在测试和知识控制方面[7]。在超声诊断模拟培训、合理使用虚拟模拟器、确定其在教育过程中的具体位置以及评估其使用效果方面,几乎没有标准化的方法。关于为掌握这种或那种类型的模拟器和仿真器而开发的特殊培训模块和方法材料及其使用效果的信息很少。

为此,我们决定以超声模拟器为例,分析我们在教学和知识控制过程中使用现代数字技术的经验。俄罗斯联邦国家预算高等教育机构俄罗斯彼得罗扎沃茨克国立大学放射诊断和放射治疗系在四年的“超声诊断”学科学习过程中使用虚拟模拟器。该模拟器供一、二年级的住院医师和接受专业再培

训的医生候选人使用。在对住院医师进行国家最终认证以及对该学科专业人员进行初级认证的过程中都会使用该模拟器。

目的

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虚拟超声模拟器的可能性和算法。评估使用模拟器与传统教学方法相比的优缺点。

材料与方法

在我们的研究中,我们评估了在教学过程中使用CAE Healthcare(加拿大)公司生产的虚拟超声模拟器Vimedix 3.2的效果。该模拟器在俄罗斯和国外市场上最为普及。它配备了多个人体模型和传感器,用于练习不同部位的检查技术,还拥有病理病例数据库。模拟器包括一台Hewlett-Packard(美国)公司生产的带无线连接的Omen笔记本电脑、一个鼠标、一个男性多功能人体模型、一个带相控阵的超声凸面传感器和一个用于连接传感器的适配器(图1)。

笔记本电脑配备了模拟超声扫描的原创软件,可以利用多平面重建技术进行二维和三维/四维解剖模式的检查。为此,还使用了Microsoft HoloLens 2(美国)混合现实技术,受训者可借助该技术以实时模式(即运动模式)观看所检查的解剖结构。在评估使用断层扫描方法获得的诊断图像时,该技术可用于在检查区域进行导航[11, 12];在模拟器中,该技术可用于在模拟过程中正确定位换能器[13]。在笔记本电脑屏幕的工作空间中,除了以二维模式获得的图像外,还显示了一个单独的窗口,其中有三维/四维动画解剖图像,显示扫描区域内的器官。操作员可以控制解剖结构的显示和窗口的划分,以方便观察(图2)。

模拟器可模拟腹部器官经腹超声波检查、经胸超声心动图检查、大血管扫描等检查。扫描模式包括:

- B(2D, 二维超声检查);
- M(一维超声检查);




图1. 虚拟超声模拟器“Vimedix 3.2”。




图2。混合现实和二维模式下的模拟程序界面。

- 彩色多普勒 (Color Doppler, CD)；
- 脉冲波多普勒 (Pulsed Wave, PW)。

传感器在人体模型表面的移动由一个特殊的标记系统跟踪，因此可以在不同体位（仰卧、侧卧）下进行检查。为了评估结果，有一套基本的必要工具，如长度、面积和容积测量，多普勒模式下的血流速度，超声心动描记术检查期间中心血流动力学参数的计算。根据检查结果和测量结果，可以生成最终方案。

虚拟模拟器拥有一个庞大的超声图像数据库，其中包含腹部器官和心血管系统的各种病理图像。因此，学员不仅可以学习正常解剖学中不同部位的检查技术，还可以学习各种疾病的检查技术。在知识控制过程中，可以评估学员根据标准化方案发现和描述不同类型病理变化的能力。

共有26名“超声诊断”专业的住院医师和37名在同一专业的专业进修班接受过培训的医生参与了研究过程。由于我们的工作采用了分类数据和两个回答选项，因此现有的专家人数足以评估建议的培训方法在超声波课程所有学员中的应用情况，不仅在工作评估期间如此，在未来也是如此。放射诊断和放射治疗部门的工作人员对模拟器的工作成果进行了评估，研究所临床基地的执业医师-诊断医师也参与了评估，并参加了培训和知识控制过程。

在我们的工作中，为了确定虚拟模拟器的使用效果，我们主要使用了组织和规划教学过程所需的指标：

- 掌握模拟器所需的时间（包括启动软件和使用界面的培训）；
- 学习的难易程度和心理舒适度；
- 操作传感器和人体模型的难易程度；

- 传感器的正确定位（借助人体模型的解剖标志和混合现实技术）；
- 学员在模拟器上独立工作的可能性；
- 是否需要特殊教材和对现有培训计划进行修正。

一些曾在诊所使用过超声波扫描仪的住院医师和学员对模拟器生成的图像质量及其与真实病人检查时生成的图像的一致性进行了评估。

采用李克特量表[14]对学员进行匿名问卷调查，对提出的问题从0到5分进行打分，从而收集数据（图3和图4）。

在授课过程中，指导教师根据评估标准对使用设备的过程进行了分析；在授课结束时，在诊所工作的指导教师和导师通过测试和任务对理论知识和实践技能的掌握情况进行了评估。我们考虑到大多数评估标准都是主观的，因此很难对结果进行解释，但这是由于超声检查的普遍特殊性，特别是它对操作者的高度依赖性。我们还与学员一起记录了培训过程中出现的问题，并分析了出现这些问题的原因和消除问题的方法。

遵守道德规范

参与培训和研究过程的人员未签署知情自愿同意书。数据收集以自愿匿名问卷的方式进行，在此过程中未收集或处理任何个人数据。患者未参与研究过程。

结果

在评估培训过程中使用虚拟模拟器的优缺点时，我们将其与传统方法进行了比较。传统方法是住院

针对“超声诊断”专业住院医师和学员的**调查问卷**
问卷不记名, **无需**提供个人资料

答案中带有截止线的问题得分从1到5, 其中
1为完全不同意; 2为不同意; 3为中立; 4为同意; 5为完全同意。

带有两个答案选项的问题中需要选择其中一个

1、我能够使用超声模拟器完全掌握工作技能。
答案__分

2、在超声模拟器上训练时, 我已完全掌握了各个部位的检查手法。
答案__分

3、对我来说, 在超声模拟器上学习技能很容易。
答案__分

4、我发现很难使用超声模拟器掌握工作技能。
答案__分

5、我会选择超声模拟器来教授超声扫描技术。
是__否__

6、我会选择对真实病人进行检查来教授超声扫描技术。
是__否__

7、我在学习如何使用超声模拟软件时遇到了困难。
答案__分

8、我的计算机科学知识足以自信地使用超声模拟器。
答案__分

9、我的计算机科学知识不足以自信地使用超声模拟器。
答案__分

图3. 针对住院医师和学员的调查问卷, 第1部分。

10、对我来说, 在超声模拟器上进行的培训比在诊所对真实病人进行检查的培训在心理上更舒适。
答案__分

11、对我来说, 在诊所对真实病人进行检查的培训比在超声模拟器上进行的培训在心理上更舒适。
答案__分

12、我更喜欢在超声模拟器上进行最后的专业测试。
答案__分

13、我更喜欢在诊所对真实病人进行最后的专业测试。
答案__分

14、对我来说, 在超声模拟器上准备最终测试比接受在诊所对真实病人进行检查的培训在心理上更舒适。
答案__分

15、对我来说, 接受在诊所对真实病人进行检查的培训比在超声模拟器上准备最终测试在心理上更舒适。
答案__分

16、与在诊所对真实病人进行检查的培训相比, 我需要更长的时间才能使用超声模拟器掌握超声扫描技能。
是__否__

17、与使用超声模拟器相比, 接受在诊所对真实病人进行检查的培训时, 我需要更长的时间才能掌握超声扫描技能。
是__否__

18、超声模拟器屏幕上内脏器官的图像质量与您使用过的超声扫描系统屏幕上的图像质量一样好 (如果您没有使用过, 请不要回答此问题)。
答案__分

评论 (就调查问卷中未列出的问题补充您的意见, 指出您在使用超声模拟器时遇到的困难)。

图4. 针对住院医师和学员的调查问卷, 第2部分。

医师和内科医生在导师 (科室成员和执业医师) 的指导下, 在诊所使用超声扫描仪对真实病人进行检查的培训。采用这种方法, 我们面临着许多已知的问题, 近年来由于COVID-19的流行, 这些问题的数量有所增加[15]。

培训结果显示了, 所有住院医师和大部分学员 (81%) 都成功完成了使用虚拟超声模拟器的培训。成功的标准包括熟练使用模拟器软件和模拟器界面 (开机、设置), 完全掌握特定部位的检查技术 (表1)。

掌握模拟器所需的最短时间为2至6门功课, 在科室教师的指导下进行2个学时的功课, 以及一次入门讲

演 (1个学时, 45分钟)。我们注意到, 住院医师掌握模拟器操作的速度普遍快于学员。我们认为, 这是由于他们的理论基础 (放射诊断课程的讲座) 和一定的超声设备工作经验。对他们中的大多数人 (75%) 来说, 在导师的指导下进行2-3次训练就足够了, 之后他们就可以按照自己方便的时间安排进行大部分的独立训练。至于受训医生, 年龄较大的受训者 (50岁及以上) 至少需要3-4次、最多6次培训才能掌握模拟器上的基本技能。与此同时, 我们还遇到了一个问题, 即部分学员 (26%) 在计算机技术领域的培训水平为零或较低, 即使在培训课程结束后, 他们也无法独立运行笔记本电脑软件和自信地使用模拟器应用界面。为了评估虚

表1. 学员的问卷调查和测试结果

	住院医师	医生
学员人数	26	37
成功掌握模拟器	100%	81%
掌握模拟器所需的最短时间, 分钟	90	135
在模拟器上掌握扫描技术时的心理舒适度	80%	68%
在模拟器上准备测试/认证时的心理舒适度	90%	75%
M和B模式下模拟器上令人满意的图像质量	95%	95%
多普勒模式下模拟器上令人满意的图像质量	90%	89%
对 3D/4D 导航程序使用情况的积极评价	100%	100%
宁愿在模拟器上进行最终测试和认证	100%	90%

**评估在超声模拟器上掌握B模式检查技术成果的测试任务
(第1个变体: 使用MR模式; 第2个变体: 不使用MR模式)。
运行时间为10分钟。**

- 1、打开虚拟模拟器, 启动超声模拟程序。
- 2、将人体模型置于_____检查的正确位置。
- 3、使用/不使用MR技术, 在纵向扫描平面上显示被检查器官_____。
- 4、使用/不使用MR技术, 在横向扫描平面上显示被检查器官_____。
- 5、确定需要测量的点, 进行测量并告知结果。
- 6、评估器官的回声密度和回声结构。报告获得的结果。
- 7、评估器官轮廓并进行描述。
- 8、如果器官出现病理变化, 请根据以下方案对其进行评估:
 - 定位
 - 大小
 - 形状
 - 回波密度和回波结构
 - 轮廓
 - 附加元素(伪影等)
- 9、制定并报告关于被检查器官的结论方案, 包括评估指标。

**评估在超声模拟器上掌握多普勒模式检查技术成果的测试任务
(第1个变体: 使用MR模式; 第2个变体: 不使用MR模式)。
运行时间为10分钟。**

- 1、打开虚拟模拟器, 启动超声模拟程序。
- 2、将人体模型置于心脏检查的正确位置。
- 3、显示心尖五腔位置的B模式心脏图像。
- 4、打开彩色多普勒血流图模式, 将被检查区域设置在二尖瓣区域。
- 5、在彩色多普勒血流图模式下演示二尖瓣流, 并评估其方向和特征。报告结果。
- 6、打开脉冲波多普勒模式, 将控制量设置在二尖瓣叶上方。显示二尖瓣流频谱。
- 7、测量速度和评估二尖瓣流频谱的性质, 并报告结果。
- 8、将彩色多普勒血流图模式的检查区域设置在主动脉瓣区域。
- 9、在彩色多普勒血流图模式下演示左心室流出道的血流, 并评估其方向和特征。报告结果。
- 10、将脉冲波多普勒模式的控制量设置在左心室流出道。演示血流频谱。
- 11、测量左心室流出道的血流速度和评估血流频谱的性质, 并报告结果。
- 12、将脉冲波多普勒模式的控制量设置在主动脉瓣上段。演示血流频谱。
- 13、测量主动脉瓣上段的血流速度和评估血流频谱的特征, 并报告结果。
- 14、根据对流经二尖瓣和主动脉瓣的血流进行多普勒模式检查的结果, 形成并报告结论。

图5. 评估掌握检查技术成果的测试任务。

拟模拟器上的工作成果, 我们使用了基于超声检查专家初级认证过程中所执行任务的测试(图5)。

相当一部分学员(72%)表示了, 在学习初级超声技能时, 与在诊所对真实病人进行检查的培训相比, 使用模拟器工作时心理上更舒适。只有在超声扫描仪上有过实际操作经验(尽管经验不多)的学员才对这一标准进行了评估。据导师和学员们自己说, 在初始阶段, 它可以促进和加快检查方法的掌握, 但不能消除与病人初次接触的问题, 这个问题必须在随后的实际工作中加以解决。这主要涉及到以前没有这种互动经验的住院医师。

模拟器的工作很容易纳入培训计划, 因为它位于医学院大楼内, 我们不依赖于医疗中心的运作模式。这也有助于解决空间不足以及在诊所培训时间有限的问题。我们已经尝试过将学生分组, 并随后进行了实践, 这样可以制定出对教师和学生都方便的培训计划。根据我们的经验, 最多3人的小组最适合同时虚拟模拟器上进行操作。这一计算方法取决于一名学员在一堂课中掌握新教材所需的时间和教室的大小。

学员普遍认为B和M模式下获得的图像质量好(95%的答案), 多普勒模式下的图像质量令人满意(89%)。标准是识别和解释所获图像的难度, 以及

将图像与实际解剖对象进行关联的可能性。使用多普勒模式时发现的问题是无法调整多普勒模式的某些参数, 因此CD和PW模式下的血流只能通过心脏瓣膜和某些主动脉部位清晰可见。

所有学员都注意到, 使用具有混合现实模式的附加窗口和对检查区域进行3D/4D-live解剖导航, 使得在检查所有区域时练习探头定位变得更加容易。这在评估腹部器官和心脏时尤其方便[12]。

在使用B模式时, 我们发现了这样一个问题, 即在获取心脏的某些标准投影(如心尖)时, 探头在人体模型上的定位并不十分正确, 这需要稍后在患者身上练习技能时进行修正。在这种情况下, 学员们成功地使用混合现实系统解决了这个问题, 准确评估了器官的横截面以及探头相对于解剖标志的位置。

根据调查问卷结果, 与在真实病人身上练习技术相比, 几乎所有(95%)住院医师和内科医生都更喜欢模拟器。在模拟器上练习技术的平均时间为1到2次, 每次2个学时。技术练习包括在人体模型的不同位置进行多位置检查, 我们没有限制一次扫描的时间, 这必须在诊所完成。当开始使用真正的超声扫描仪时, 我们对所掌握的检查不同区域的技能表示满意, 只需要在探头定位和处理“疑难病人”及某些呼吸阶段的能力方面进行少量的时间修正。

在教学方法上, 我们认为应与导师指导诊所的做法有所不同。在那里, 两个主要方法是观察研究和重复导师在病人身上的动作, 而在这里, 除了观察研究和重复导师在病人身上的动作外, 还可以采用试错自学的原则。我们认为, 这种方法对学生来说更容易接受(至少没有时间限制和心理压力), 并能取得更好的实际效果。我们在培训过程中采用了这种方式, 即学生根据自己方便的时间安排在模拟器上独立工作。必要时, 教师通过音频和视频链接以远程形式提供咨询。

此外, 在初始阶段, 还可以从传统的“一名导师——一名学员”计划转为小组培训制度, 这从经济角度来看更为有利。通过模拟器, 可以在一节课内将所学材料的理论部分和实践部分结合起来。首先, 教师就这一主题或那一主题进行入门讲演, 并在模拟器上进行演示, 然后在学生的实际操作中巩固所学知识(图6)。事实证明了, 这一原则在学习某些领域的初步检查方法和准备测试时非常方便。

至于在住院医师认证和专科医师资格认证过程中使用虚拟模拟器控制知识的问题, 已经取得了模棱两可的结果, 为讨论提供了机会。在许多此类研究中, 作者都强调了使用模拟器的积极意义, 特别是不会给受试者造成压力, 而且条件接近现实[8, 15]。这些数据与大多数学生(95%)的意见一致, 根据调查问卷结果, 他们更倾向于在模拟器上通过实践技能测试, 而且这种评价在测试前后的各个阶段都是一致的。不过, 据系里的工作人员和实习指导教师说, 这种测试方法的消极方面多于积极方面。

讨论

因此, 根据虚拟模拟器Vimedix 3.2的使用结果, 建议在“超声诊断”专业培训的初始阶段使用该模拟



图6。一名二年级住院医师在模拟器上的独立工作。

器。我们的经验证实了将虚拟现实和增强现实系统融入医学教育过程和超声诊断培训课程的实用性,正如许多作者所指出的那样[8–10, 15]。在模拟器的帮助下,可以很方便地练习某些部位的检查手法,使用解剖标志定位探头,学习在各种模式下进行基本测量,包括多普勒测量。然而,模拟器的使用并不能取代临床经验,而只是对临床经验的补充,在后续阶段,应在导师的指导下,在检查真实病人时反复练习(和修正)实际技能。

关于通过模拟训练获得的技能与临床效果之间的相关性,以及这些技能的长期可持续性,相关数据还相对较少[16, 17]。因此,我们认为,为了更准确地评估培训效果,最好在毕业生开始独立工作数年后对其进行实际测试控制。为此,可采用超声技能客观结构化评估(OSAUS)标准系统[18]。

为了有效地掌握模拟器,最好准备一份单独的使用指南,包括启动应用程序的时刻,以及在某些任务中以分步操作的形式对界面使用的指导。对于学生的独立工作,最好准备一个入门讲演,让住院医师和学员熟悉模拟器软件的基础知识,并由教师演示其功能。在这方面,关于在模拟器上检查人体模型某些解剖区域的方法建议也很有用。为了让学生掌握检查某些部位的方法,采用了两个学时的培训模块,一个是教师演示教材,另一个是学生独立完成。由于学生在计算机科学方面的培训水平不同,可以使用两个版本的培训计划,即在模拟器软件的操作技能方面分别投入更多和更少的时间。

一般来说,要完全掌握模拟器的功能,至少需要5–6次由教师指导的课程,这些课程分布在不同的学习领域。这些课程可能包括重复正常解剖、定位练习、超声模式的使用、器官评估参数等主题。今后,学生可以在自己方便的时候独立工作,包括在教师的远程控制下解决出现的问题。此外,虚拟模拟器还可利用软件中包含的病理病例数据库,用于学员在诊所检查真实病人时没有遇到的疾病的诊断。

至于知识的最终评估,我们认为最好是在超声扫描仪和真实病人身上进行,这样才有可能确定受试者在特定临床情况下的鉴机能力。在这种情况下,最佳

的方法似乎是检查没有病理变化的患者和存在某种疾病的患者,尽管难度更大,但住院医师或学员应向导师展示并在标准方案中正确描述。住院医师和学员之所以倾向于使用模拟器,是因为与在诊所进行的测试相比,准备和进行实际测试本身在心理上更为舒适。它不耗费时间,不涉及病人和临床设备,可以随时独立进行,学员本身也不会感到紧张。

从教师的角度来看,实践技能测试的准备工作主要是对某些动作的记忆。在测试过程中,专家也主要评估某些动作的执行和顺序,而不是其质量和结果。检查表和远程观察系统无法详细评估考生所接收图像的正确性,也无法在有疑问的情况下布置额外的任务。没有可能对不同类型病人的体格进行评估,在没有呼吸运动的情况下评估标准化的正常解剖图像,也不进行多位置扫描。不过,这里的问题已经不是模拟器本身的操作原理和功能,而是现有的测试方法和原则。

如果我们对虚拟超声模拟器Vimedix 3.2的程序技术装备进行评估,它可以对专家在培训过程中应该掌握的主要检查类型进行相当完整的模拟。在这方面,我们认为可以对其进行改进并扩大其应用范围,以培训在超声控制下对各种器官进行穿刺和对胃肠道进行回声内窥镜检查等相关技术。

结论

Vimedix 3.2模拟器应在超声专家培训的初始阶段使用,以练习不同部位的检查技术,包括特定的临床情况。我们认为,在这一阶段使用模拟器进行认证和鉴定不如在临床上对真实病人进行测试。为了充分利用模拟器,建议在培训中开发和使用更多的方法材料和培训模块,改变掌握实际技能的方法。

在教学过程中使用虚拟模拟器Vimedix 3.2的主要优点是:学生工作起来心理舒适、掌握时间短、可以小组合作、有大量病例数据库、位于医学院大楼内。

已发现的使用模拟器的缺点包括无法练习与病人一起工作的实际操作、探头定位错误以及CD模式下的图像质量不尽人意。这些缺点并不严重,但需要在临床工作中进一步修正所掌握的技能。

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. 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.

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. Ovsiannikova 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, Todsen T, Sorensen 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

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 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

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

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

* Corresponding author / Автор, ответственный за переписку

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>

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>

将机器学习技术应用于眼内镜片光学倍率的预测：诊断数据的概括化

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：诊断数据的概括化. *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

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问题。然而，患者视觉功能的改善程度与术前眼内镜片光学倍率计算的准确度直接相关。因此，眼科使用各种公式来计算这一指标。最著名的公式包括SRK II、SRK/T、Hoffer-Q、Holladay II、Haigis和Barrett[1-7]。所有这些公式对“中等症患者”都很有效，但在输入变量范围的极端情况下则不够充分。它们还有其他缺点：首先，它们没有考虑到对象的非平稳性，当引入新的经验数据时，例如在对模型进行本地化时，不允许更改设置；其次，考虑的输入因素数量明显不足。这些情况导致对上述公式的许多局部修正和不断调整[2, 8]。

俄罗斯杰出的眼科专家S.N.Fedorov (1967年) [1, 2]提出了第一个基于光学定律和示意眼数据的计算眼内镜片光学倍率的公式。在随后的几年中，直到现在，眼科实践中最常用的计算眼内镜片光学倍率的公式是SRK/T、SRK II、Hoffer-Q、Holladay II、Haigis和Barrett[3-7]。国外最早的眼内镜片光学倍率计算公式出现在20世纪70年代末和80年代初。它们要么是理论公式，要么是回归公式。回归公式受到外科医生的青睐，其中最成功的是SRK，由D.R.Sanders、J.A.Retzlaff和M.C.Kraff开发出的[3-5]。

目前，基于人工神经网络的人工智能系统得到了前所未有的发展，通过利用大量经验数据进行深度学习，几乎可以在包括生物学和医学在内的任何学科领域建立适当的模型[9-12]。此外，现代眼科中心在过去几十年中建立了病人数据存储库，其中包括数万乃至数十万条数字化参数记录。

在这种情况下，可以认为解决术前眼内镜片计算问题的根本方法是建立一个智能专家系统，其核心是使用人工神经网络（人工神经网络模型）建立的数学模型。这种模型可以根据数据存储库中的数据进行训练，与已知公式相比，可以考虑更多的重要输入因素和患者的地区特异性。根据数据存储库中的新数据对人工神经网络模型进行逐步的再训练，必要时对其结构进行修改，这将提高其适应性，并消除考虑对象非平稳性和模型本地化的问题。

建立这种智能专家系统的第一阶段是利用人工神经网络模型解决大量患者经验数据的概括化（概括化的可能性）这一根本问题，确定重要的观察输入因素，并比较这种模型与已知公式的适当性[1-7]。

目的

研究俄罗斯一家眼科中心在使用人工神经网络模型深度学习对患者进行治疗的过程中获得的大量眼内镜片计算经验数据的概括化可能性；确定对术前眼内镜片计算误差有重大影响的最重要的观察输入因素；比较使用人工神经网络模型和已知公式计算的误差。

计算眼内镜片光学倍率的误差

此前，我们根据S.N.Fedorov Eye Microsurgery 医学中心（坦波夫，俄罗斯）以匿名形式提供的大量经验数据[13]，比较了一些公式的使用误差。原始数据于2014年底获得。初始记录数为28940条。每条记录包含以下参数：

- 匿名患者编号；
- 手术日期；
- 植入的眼内镜片的品牌名称和光学倍率；
- 患者年龄；
- 眼睛长度；
- 用于矫正屈光和散光异常（球面和柱面）的眼内镜片所需的光学倍率；
- 与眼内镜片在眼球中的位置有关的其他信息。

已处理的记录总数为11701条。同时，由于缺少镜片参数或字段数据不正确，有17239条记录未被处理。Haigis、Holladay、SRK II和SRK/T公式被认为最接近经验数据。

表1给出眼内镜片计算的平均相对误差值。根据这些公式计算出的所需眼内镜片光学倍率与计算出的眼内镜片光学倍率之间的相关性可见图1。在计算眼内镜片的平均光学倍率时，所有公式得出的结果都接近所需值，但在极值处，相对于所需值有明显的偏差。

因此，相对于精确计算所对应的对角线，在依赖关系的斜率上可以观察到明显的数值差异（图1，a、b、d）。在所有研究的公式中，都使用了三个参数作为输入值：眼睛长度（mm）（L）、眼球子午线算术平均值（mm）（K）以及作为镜片参数的前房深度。这一事实不可避免地意味着存在其他因素（可能是未观察到的）。它们对眼内镜片光学倍率的影响导致了上述计算特征。

在同一项研究[13]中，我们介绍了通过使用非线性编程方法11701名患者的均方误差最小化而得到的优化回归公式。通过引入第四个变量，我们将平均相对误差降低到了10.6%。这意味着必须考虑更多的输入变量，最好还能考虑所有相关的患者信息。在这种情况下，预测眼内镜片光学倍率的工具就是使用人工神经网络模型。

与我们文章最接近的是一项研究[14]，该研究旨在描述在白内障摘除术中使用机器学习预测术后屈光，并比较模型与传统计算眼内镜片光学倍率公式的准确度。训练样本包括来自2010名患者（3331只眼睛）的数据。通过对数据的训练，对模型系数进行了优化。

表1。使用不同公式得出的眼内镜片光学倍率计算误差比较

计算公式	计算眼内镜片的平均相对误差， %
Haigis	15.6
Holladay	13.4
SRK II	11.7
SRK/T	12.5




图1. 11701名患者的所需眼内镜片光学倍率（横轴）与计算出的光学倍率（纵轴，根据公式）之间的相关性：a——Haigis；b——Holladay；c——SRK II；d——SRK/T。相关系数见图。

然后，作者使用常用公式（SRK/T、Haigis、Holladay II、Hoffer-Q 和 Barrett Universal II 公式（BU-II））预测术后屈光的发生。一些机器学习方法的绝对误差低于使用公式计算的误差。不过，在统计学上并未发现明显差异。

在我们看来，获得的结果在意料之中，因为作者没有使用额外的输入参数，而机器学习和通常用于公式参数识别的最小二乘法，通常会得出相似的结果。在本研究中，我们分析了在使用更多输入参数的情况下使用人工神经网络模型预测眼内镜片光学倍率的可能性。

由于以下原因，有关眼内镜片计算的工作仍在进行中：

- 需要减少误差；
- 出现以前计算中没有考虑的新因素数据（以前只考虑4个输入因素，而现在考虑了26个）；

- 希望开发一种适应的眼内镜片计算模型，以便在收到新数据时考虑到可能出现的非平稳性；
- 希望创建一个具有动态数据输入功能的专家系统，并利用人工神经网络模型对其进行逐步训练。

材料和方法

2021年，眼科医生K.K.Syrykh以匿名患者术前和术后检查结果的形式提供了原始数据。用于建立人工神经网络模型的初始数据文件包括455条记录：26列输入因素和一系列输出因素，即眼内镜片计算（dptra）。为方便起见，输入参数用 x_1-x_{26} 表示，输出参数用Y表示。输入变量见表2。

作者先前开发的模拟器程序[15]被用于方便地建立人工神经网络模型。

表2。基于人工神经网络建立模型的输入参数

参数	意义	参数	意义
x_1	性别	x_{14}	眼睛长度（光学生物测量，mm）
x_2	术前未矫正视力	x_{15}	术后未矫正视力
x_3	根据术前视力检查数据得出的球面屈光成分	x_{16}	根据术后视力检查数据得出的球面屈光成分
x_4	根据术前视力检查数据得出的柱面屈光成分	x_{17}	根据术后视力检查数据得出的柱面屈光成分
x_5	根据术前视力检查数据得出的柱面轴线	x_{18}	根据术后视力检查数据得出的柱面轴线
x_6	术前矫正视力	x_{19}	术后矫正视力
x_7	术前角膜强子午线轴线	x_{20}	术后角膜强子午线轴线
x_8	术前角膜强子午线屈光	x_{21}	术后角膜强子午线屈光
x_9	术前角膜弱子午线轴线	x_{22}	术后角膜弱子午线屈光
x_{10}	术前角膜弱子午线屈光	x_{23}	术后角膜低位经线屈光度数
x_{11}	根据术前屈光检查数据得出的球面屈光成分	x_{24}	根据术后屈光检查数据得出的球面屈光成分
x_{12}	根据术前屈光检查数据得出的柱面屈光成分	x_{25}	根据术后屈光检查数据得出的屈光柱面成分
x_{13}	根据术前屈光检查数据得出的柱面轴线	x_{26}	根据术后屈光检查数据得出的柱面轴线

结果

在开发人工神经网络模型的过程中，接受有关网络结构（架构）的假设是最具挑战性的问题之一。

众所周知，使用A.N.Kolmogorov定理[16, 17]往往会导致人工神经网络模型结构冗余。通常，这样的模型能很好地表示节点处的输出变量，但预测能力较弱。

在研究[18]中，我们提出了一种建设性算法，允许增加隐藏层中神经元的数量和隐藏层的数量，直到达到某些条件。我们使用了神经元的线性、二次、三次和其他传递函数，而不是常用的S型函数。我们的方法基于将多个变量的函数分解为泰勒级数(1)–(2)。在分解一个包含大量变量的函数时，有必要首先引入一个微分算子：

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

函数 $f(x^{(1)}, x^{(2)}, \dots, x^{(n)})$ 在泰勒级数中的展开式如下：

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

这种方法可以获得结构相对简单、具有良好近似（概括）和预测能力的神经网络。

根据公式(1)和(2)建立的人工神经网络模型有4层：

- 1)输入神经层；
- 2)与泰勒级数的几个项相对应的功能隐藏层；
- 3)概括隐藏层；
- 4)输出层。

功能隐藏层包含具有与泰勒级数项相对应的传递函数的神经元：线性（一阶）、二次（二阶）和三次（三阶）。概括隐藏层包含一个线性神经元，其主要功能是计算数列的几个项之和，并在其中添加一个常数。这种结构使我们的人工神经网络模型达到了可接受的准确度。

模型值与经验值偏差的平方和被用作损失函数。

在根据经验数据训练模型时，选择了以下优化方法：随机梯度法、简单的梯度法、无梯度的高斯-赛德尔坐标下降法和蒙特卡洛坐标下降法，这些方法都是交互式使用的。

从代表26个输入神经元和一个隐藏层中线性神经元的网络开始对基于眼内镜片数据的人工神经网络模型进行训练。这样的机构与公式(1)和(2)中的自由项和第一项相对应。考虑到以往研究的建议[8-11]，模型训练过程在整个样本的70%上进行，人工神经网络模型的预测能力在剩余的30%样本上进行评估。用于训练和测试模型适当性的数据是从一个通用表格中随机选取的，随机变量分布均匀。

这一简单模型的训练结果见图2。在每个病例中，特定类型的眼内镜片产生屈光正常的真实光学倍率是由植入眼内镜片的光学倍率和由此产生的屈光不正之和决定的。屈光不正是通过术后1至6个月的回顾性分析计算得出的。

就平均相对误差而言，所获得的结果与经典公式相当，但在本例中，我们使用了包含26个变量的线性




图2。基于一阶模型的计算数据 (Ymod) 和经验数据 (Ytab) 之间的相关性。对相关系数为0.84；平均相对误差为11.9%。

函数来预测眼内镜片光学倍率。计算数据与经验数据之间的对相关系数为0.71，平均相对误差为11.9%。

线性模型通道的突触连接系数代表通道的灵敏度，其值可用来估计通道对输出变量的影响程度。数值实验表明了，至少有12-15个输入因素（眼科医生

可获得的）会对眼内镜片光学倍率的术前计算产生重大影响。因此，我们关于必须考虑更多输入量以减少计算误差的假设得到了充分证实。同样明显的是，经典公式[3-7]的重大误差也与大量输入因素的存在有关，而这些因素在这些公式中是不观察的。

有些因素（如 x_{16} 、 x_{21} 、 x_{23} 和 x_{24} ）的值只有在术后才能知道。不过，它们与术前的类似因素有很好的相关性，因此其值是可以很好预测的。

按照我们的算法[18]，我们改变了人工神经网络模型的结构，在隐藏层中加入了一个二次神经元和一个线性神经元。使用类似的非线性编程数值方法训练这样一个人工神经网络模型，使我们能够将平均相对误差降低到5%。因此，之前的结果提高了2倍。同时，对相关系数为0.97，平均相对误差为4.8%（图3）。

按照这一逻辑，我们还建立了一个三阶人工神经网络模型，该模型的隐藏层包含具有线性、二次方和三次传递函数的神经元。使用类似的非线性编程数值方法训练这样一个人工神经网络模型，使我们能够将平均相对误差降低到3.5%的水平，对相关系数为0.98（图4）。

值得注意的是，该人工神经网络模型的自由度数等于突触连接数（ $26 \times 3 + 3 = 81$ ），明显小于训练样本中的记录数。这一事实表明，使用人工神经网络模型计算眼内镜片光学倍率的经验数据具有良好的概括化。

不同眼内镜片光学倍率计算方法的比较结果见表3。因此，与传统方法相比，当使用人工神经网络模型和更多输入变量时，计算的平均相对误差可减少2倍以上。




图3。基于二阶模型的计算数据 (Ymod) 与经验数据 (Ytab) 之间的相关性。对相关系数为0.99；平均相对误差为4.8%。




图4。基于三阶模型的计算数据 (Ymod) 与经验数据 (Ytab) 之间的相关性。对相关系数为0.99；平均相对误差为3.5%。

表3. 使用不同方法计算眼内镜片光学倍率的平均相对误差以及计算数据与经验数据之间的相关系数的比较结果

公式或人工神经网络模型	平均相对误差, %	计算数据与经验数据之间的相关系数
Haigis	15.6	0.85
Holladay	13.4	0.86
SRK II	11.7	0.86
SRK T	12.5	0.86
线性人工神经网络模型	11.9	0.84
二阶非线性人工神经网络模型	4.8	0.98
三阶非线性人工神经网络模型	3.5	0.99

讨论

该方向下一阶段的研究应该是收集更多的匿名术前和术后患者检查数据, 因为深度机器学习方法需要大量的训练样本, 之后应该对模型在测试样本上进行验证[11-14]。如果系统还包含超参数(必须“从上面”设置的参数, 问题的解决取决于能否成功引入这些参数), 则应使用第三个额外的验证数据样本。有了这些数据, 就有可能建立一个用于术前计算眼内镜片的智能专家系统。我们已经介绍了建立这种系统的一些原则[19]。

结论

与使用传统公式和方法相比, 使用深度学习人工神经网络模型计算眼内镜片光学倍率时, 输入变量的数量要多得多。确定对目标指标有重大影响的最重要的观察因素, 并将其纳入人工神经网络模型, 可将计算误差减少2倍以上。基于人工神经网络的模型能够很好地概括数据, 这为创建智能专家系统提供可能性, 该系统可动态输入新数据, 并逐步对智能核心进行深度机器学习。与使用传统计算公式相比, 这种系统的主要特点是适应性强, 可以解决对象非平稳

性的问题, 以及由于其中存在反馈而导致的本地化问题。目前, 已开发的人工神经网络模型被用于眼科医生助理模式, 并与其他工具相结合, 以计算术前眼内镜片光学倍率。

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.A. Arzamastsev — research concept, data processing, writing the manuscript, editing the manuscript; O.L. Fabrikantov — research concept, literature analysis, editing the manuscript; N.A. Zenkova — data processing, literature analysis, editing the manuscript; S.V. Belikov — preparing the dataset, searching for publications.

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 AYu, 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. Arzamashev 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

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., Белосов 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

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

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

* Corresponding author / Автор, ответственный за переписку

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>

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>

机器学习和人工神经网络技术在角膜切开术后角膜畸形分类中的应用

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角膜畸形分类中的应用. *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

论证

眼科疾病诊断中眼科检查范围的扩大大增加了保健负担,尤其是眼科诊所的负担。与此同时,深度机器学习和人工神经网络等技术可以使分析结果的过程自动化,提高病理检测的准确性和速度,并使医生活动中的决策过程自动化。在眼科疾病的诊断中,机器学习模型在眼底图像、晶状体混浊、青光眼时的视神经变化以及眼压测量数据的评估中体现得最为明显。此外,机器学习和人工智能还被广泛用作诊断角膜病变的方法。在角膜病理学研究中,圆锥角膜的诊断备受关注[1-6]。卷积神经网络(convolutional neural networks)尤其擅长模式识别和图像分类任务,这使得这些算法成为自动分析彩色编码Scheimpflug相机图像的合理选择[7]。V.A.Dos Santos等人开发并训练了用于角膜光学相干断层扫描图像分类的CorneaNet神经网络(奥地利)[8]。台湾科学家B.I.Kuo等人对角膜地形图结果进行了回顾性评估,从而开发出一种用于角膜病诊断的深度机器学习算法[9]。S.Shi等人的研究表明了,利用机器学习结合Scheimpflug相机图像和超分辨率光学相干断层扫描,在亚临床圆锥角膜和正常角膜的鉴别诊断中表现优异[10]。最近的几项研究表明了,卷积神经网络技术在角膜内皮图像分类算法中自动检测Fuchs内皮营养不良症的有效性[11]。

与此同时,以前接受过前放射状角膜切开术的老年性白内障和近视患者也在不断增加。值得注意的是,前放射状角膜切开术是首个大规模屈光手术,为世界上大量患者解决了近视矫正的重要问题。众所周知,前放射状角膜切开术的屈光效应是基于角膜中心区构造的改变而引起的角膜处光功率的变化,而角膜中心区构造的改变是由于在眼内压作用下,放射状定量切口部位角膜生物力学特性的局部减弱而引起的。在开发阶段前放射状角膜切开术应使两个角膜表面均匀变平,并保持角膜曲率半径的比例。然而,角膜畸形的特征受眼睛初始参数(角膜的生物力学特性、近视程度、眼压水平)、手术因素(切口的数量、深度和长度、手术质量)、再生过程和瘢痕的个体特征、手术时患者的年龄、患者的生活方式、衰老过程等的影响。这就是为什么在前放射状角膜切开术后的远期,角膜会发生明显的畸形变化,这在计划进行白内障手术并植入眼内镜片时尤为重要。

白内障患者的角膜曾接受过手术改造,如果术前对角膜光学特性的分析出现错误,可能会导致白内障手术后出现屈光不正和视力质量低下等致命后果。因此,对前放射状角膜切开术后患者的角膜地形图进行全面分析,制定角膜切开术后角膜畸形的分类标准,并创建自动分类系统,可以为白内障手术的个性化治疗奠定基础,并提高此类患者眼内镜片光学倍率计算的准确性。

目的

基于对角膜地形图数值的分析,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。

材料和方法

本研究以2020-2023年期间去俄罗斯联邦卫生部联邦国家自治机构伊尔库茨克分部国立《S.N.Fedorov“眼显微外科学”跨部门科技联合体》医学研究中心的250名46至76岁(平均年龄为 59.63 ± 5.95)患者的匿名病历结果为分析材料。除了标准的眼科检查外,所有患者都在Pentacam HR设备(Oculus,德国)上接受了角膜地形图检查。作为角膜光学特性的特征,记录了38个角膜前后表面高度参数和12个反映角膜厚度、屈光力、散光值和非球面度的参数。研究分三个阶段进行。

第一阶段:分析角膜前后表面的地形图

数据集包括500张地形图(Pentacam 4 maps refractive显示屏)中角膜前后表面各19个数字高度值。高度数据记录在三个环形区域:中心区、旁中心区的4个点以及位于直径6mm圆线上的周边区的14个点。研究从位于90度的一个点开始,然后顺时针方向转动。角膜高度图上地形图点的位置示意图见图1。

第二阶段:深度学习机构和可视化

对以开发机构的训练和测试过程是在一台个人电脑上进行的,其软件和硬件如下:Windows 10操作系统、AMD Ryzen™ 7 2700E处理器、16GB RAM。




图1. 角膜表面的控制点: a——角膜中心; b——旁中心区; c——周边区, 直径为6mm。




图2。处理数据集的过程。

需要注意的是，图形处理器并未用于模型训练，所有必要的计算均在中央处理器上进行。编程时使用了带有Anaconda发行版的Python 3.10语言，特别是tf.keras 2.12.0库。在TensorFlow框架2.0版本中使用了Keras API规范实施。

数据集包含一个关键参数，即“类型”，用于描述患者角膜前后表面高度。根据地形图确定了角膜切开后角膜畸形的类型。根据角膜前后表面高度模式，共确定了6种类型（表1）[14]。

在这一阶段的工作中，对数据集进行了优化：使用相关性和回归分析对所有参数的性质进行了研究，并根据研究结果排除了低信息量特征（图2）。参数“类型”仅用于测试神经网络的训练情况，不作为输入参数使用。

第三阶段：创建人工神经网络

人工神经网络包含三个层：输入层、隐藏层和输出层：对于执行分类任务的神经网络来说，这个层数已经足够了。输入层神经元数M=12（参数），输出神经元数为6（类别）。隐藏层的神经元数量按公式 $M = \frac{2}{3} \times N + K$ 计算，其中N为输入神经元数量，K为输出神经元数量。

本研究的任务是创建一个可与输入特征表配合使用的人工神经网络。人工神经网络的示意图见图3。

结果

在开发神经网络的过程中，我们创建了一个简单的控制台界面，可通过测试样本对训练进行自动检查（图4）。该界面被用于配置和选择最佳训练Epoch数。后来，在创建了必要的模块后，繁琐的界面让位于更简约的控制台输出。这一过程加快了训练速度，降低了复杂性，提高了模型的准确性。

为了更客观地感知神经网络训练的效率，可以分批进行模型训练，并比较每个训练周期（每个Epoch）的平均指标。在对数据集进行优化以及在进行相关

性和回归分析后剔除不重要参数前后神经网络平均训练指标的依赖关系图见图5。结果发现了，在对数据集进行同质变量清理和回归估计分析后，训练过程明显加快。如果没有准备阶段，同样的过程需要更长的时间，但最终版本的算法也无法达到高精度和稳定的训练效果。

由此产生的原型神经网络并不总是能够识别畸形的类型，尽管在这个过程中，它们逐渐被训练得能够更有效地完成分类任务（图6）。

此外，还可以观察到第4和第5角膜切开后角膜畸形类型经常出现错误（见图6）。鉴于这些类别在所使用的数据集中最为罕见，这可能是类别不平衡问题的一种表现形式。尽管在训练的第200个Epoch时，类别之间的差异和类别定义的错误实际上已经消失，但在训练过程中发现错误的往往是第4和第5种类型。这可能是由于每个新的人工神经网络都是从神经元的随机初始状态开始训练的，但大多数误差往往分布在第4和第5种类型之间的总体趋势依然存在（图7）。

平均而言，在第200个训练Epoch时，最终迭代的人工神经网络显示了91%的正确答案（12个中有11个）。然而，测试样本的规模并不是很大，随着测试
















图3。最后一次迭代的人工神经网络示意图。

表1. 取决于角膜前后表面高度模式的角膜切开术后角膜畸形分类类型

畸形类型	角膜前表面高度模式	角膜后表面高度模式
1	非闭环* 	非闭环* 
2	闭环* 	非闭环* 
3	闭环* 	闭环* 
4	非闭环* 	闭环* 
5	不规则 	不规则 
6	“非闭环”或“闭环” 	不规则，出现明显的后表面高度位移（大于80μm） 

*高度不超过80μm

```
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]<--- 模型答案
[112233445566]<--- 正确答案
正确答案数: 11 /12
```

图4。控制台程序的神经网络操作界面（神经网络的错误答案和其校正用红色标出）。




图5。学习率与Epoch的关系图：*a*——优化前；*b*——优化后。

```
1/1 [=====] - 0s 49ms/step
[122333420126]<--- 模型答案
[112233445566]<--- 正确答案
正确答案数: 6 /12
1/1 [=====] - 0s 20ms/step - loss: 2.6415 - accuracy: 0.5000
模型 sequential_82 训练Epoch: 160
1/1 [=====] - 0s 46ms/step
[212333421126]<--- 模型答案
[112233445566]<--- 正确答案
正确答案数: 6 /12
1/1 [=====] - 0s 21ms/step - loss: 6.7181 - accuracy: 0.5833
模型 sequential_83 训练Epoch: 170
1/1 [=====] - 0s 48ms/step
[112233321136]<--- 模型答案
[112233445566]<--- 正确答案
正确答案数: 7 /12
1/1 [=====] - 0s 21ms/step - loss: 3.3654 - accuracy: 0.8333
模型 sequential_84 训练Epoch: 180
1/1 [=====] - 0s 47ms/step
[112233441516]<--- 模型答案
[112233445566]<--- 正确答案
正确答案数: 10 /12
```

图6。神经网络的渐进式训练以及随后按控制点对模型的验证。




图7. 确定角膜切开后角膜畸形类型的误差比。

样本的增加, 训练部分也在减少, 其中第4和第5种类型由于数据量较少而受到的影响尤为严重。从每个给定类别中减少2条记录的样本会导致平均积分率在第200个Epoch时降至75%。

讨论

本研究强调了使用人工神经网络对前放射状角膜切开后经手术修改的角膜轮廓进行诊断分类的潜力。200个训练Epoch后获得的数据显示, 在测试样本和训练样本的不同比例下, 结果令人满意, 达到75–91%的范围。与此同时, 如果出现第4和第5类分类错误, 则需要增加数据集。分类准确度在一定程度上与前面介绍的构建人工神经网络的计算准确度相关。

例如, M.C.Arbelaez等人(2012年)研究了支持向量机在圆锥角膜患者角膜地形图数据分类中的有效性。他们的研究取得了很高的灵敏度和特异度, 分别为92.0%和97.7%。研究强调了, 与仅分析角膜前表面相比, 加入角膜厚度及其前后表面的数据将显著提高亚临床圆锥角膜的检测率[15]。我们还可以提及R.Hidalgo等人(2016年)的研究, 与单参数分析(0.922对0.809)相比, 使用支持向量机对角膜地形图数据进行的参数分析显示出更高的准确性(ROC曲线下方的面积值更高)。总体分类的平均灵敏度和特异度分别为89.0%和95.2%, ROC曲线下面积为0.922[16]。

结果表明了, 通过适当调整学习过程、准备输入数据、使用较大的训练样本和选择最佳机构, 可以在角膜切开后角膜畸形分类问题上获得非常高且稳定的指标。此外, 消除类不平衡问题也很重要, 这对人工神经网络的训练质量有积极影响。虽然所使用的交叉熵误差估计方法大大减少了这一问题, 但我们不能排除一个事实: 第4和第5种类型作为最少的类型, 所受的影响最大, 包含的误差也最多。

通过对记录进行独立聚类来研究数据集中的现有类别看起来很有前景。这将允许消除原划分的主观因素。

还应指出的是, 本研究展示的是利用输入特征表构建人工神经网络的结果。不过, 所获得的数据是进一步构建直接使用角膜地形图的人工神经网络的基础。

结论

在分析角膜地形图数值的基础上, 开发了一个人工神经网络, 成功解决了角膜切开后角膜畸形类型分类问题, 准确性高达91%。该角膜切开后角膜畸形的训练质量还有进一步提高的潜力。应用人工智能算法可以成为对角膜切开后角膜畸形患者进行自动分类的有用工具, 从而提供及时、高质量的诊断, 并确定进一步的患者管理策略。

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.

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

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.compbiomed.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. Малугин 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., Юрьева 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.ophttha.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

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

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

* Автор, ответственный за переписку / Corresponding author

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>

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>

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

论证

俄罗斯联邦通过的《国家人工智能发展战略》¹规定,要利用人工智能提高各种所有制组织的生产率。这可以通过实现常规(重复性)生产流程和操作的自动化来实现。

根据目前的临床指南,建议糖尿病视网膜病变和老年性黄斑变性患者在存在疾病进展风险因素的情况下,定期接受眼科医生的检查,以便动态监测病情变化,并在必要时采取适当的治疗措施[1, 2]。使用计算机分析仪进行视网膜检查,即结构光学相干断层扫描(OCT),是糖尿病视网膜病变和老年性黄斑变性的初级专科医疗标准的一部分,也是一项经常性服务²。就诊次数是根据计划的治疗策略和临床表现的特殊性单独确定的。根据国内研究,医疗机构在对老年性黄斑变性和糖尿病性黄斑水肿患者进行动态随访时,每年至少要对视网膜黄斑区进行1629429次光学相干断层扫描检查。

国外的分析报告显示,患者愿意在动态疾病监测中改用可控的自我治疗(根据STADA Health Report 2020的2019年数据,高达54%的受访者愿意改用可控的自我治疗),并愿意在没有医疗专家面对面咨询的情况下,利用远程医疗技术远程接受部分医疗服务[3-5]。根据全俄社会舆论研究中心的研究结果,48%的俄罗斯人允许使用远程医疗服务进行动态监测和矫正治疗[6]。因此,作为眼球后段病变动态监测的一部分,为反复预约诊断的患者提供人工智能医疗服务,包括使用远程医疗技术,是有组织和临床先决条件的。

尽管根据俄罗斯联邦卫生部于2012年11月12日第902n号命令《关于批准成年居民眼部及其附属器官和眼眶疾病医疗服务》要在综合医院的医疗咨询和诊断部门配备光学相干断层扫描仪,但视网膜病变患者在开始治疗后的动态监测通常在眼科医疗中心进行。这就减少新诊断病理患者的治疗机会,而这些患者需要尽早开始治疗。现有技术需要改进和加强,包括使用人工智能技术。

目的

利用基于人工智能的医疗决策支持系统,开发对眼球后段病变患者进行防治观察的组织技术方法论基础。

材料与方法

内容分析被用于评估现有的管理框架。社会学和专家方法被用于创建结构化参考书。分割和分类方法被用于进行人工神经网络的训练。

研究设计

根据对《俄罗斯联邦宪法》、联邦法律、附属管理框架和司法实践的分析,对现有管理框架进行了评估。专家方法被用于制定了光学相干断层扫描图片描述结构化医疗文件的方法论:对100名具有相应教育水平(包括接受过额外专业培训)的眼科医生进行了问卷调查,这些眼科医生从事医疗服务工作,为眼球后段病变患者提供专门医疗服务。结构化医疗文件是生成人工神经网络预测器的基础。注释后,对60000张医学图像进行了描述。每张图像都有一个json文件,描述注释后图像上存在的特征。采用DenseNet121架构的神经网络在没有预先训练权重的情况下进行训练,对图像中的二元特征进行了分析和分类。在分割任务中,使用了Mask R-CNN架构。

纳入标准

当70%的受访者同意将某一征兆纳入表明临床过程恶化的重要征兆组成时,该征兆即被纳入。当accuracy指数(灵敏度和特异性的平均值)达到0.7或更高时,即可将某一征兆纳入医疗决策支持系统结论。

执行条件

该数据库是根据俄罗斯联邦卫生部联邦国家自治机构奥伦堡分院和坦波夫分院国立《S.N.Fedorov“眼显微外科学”跨部门科技联合体》医学研究中心进行的临床检查(使用计算机分析仪进行视网膜检查)的匿名数据建立的。在奥伦堡国立大学数字智能技术研究所对人工神经网络进行了培训。

研究时限

临床检查(使用计算机分析仪进行视网膜检查)于2015年至2023年进行,描述黄斑视网膜区域的结构化二元分类器-考书的创建于2022年进行,人工神经网络的训练于2022年至2023年进行。

医疗干预措施描述

对于数据库集来说,视网膜检查是通过计算机分析仪进行的:视网膜黄斑区的光学相干断层扫描。

主要研究成果

在组织对眼球后段病变患者的防治观察中使用人工智能的方法论基础已经得到开发和评估。

分组分析

防治观察方法论是根据对被诊断为“老年性黄斑变性”(《国际疾病分类》第10次修订版中的代码编号:H 35.3)或“糖尿病性黄斑水肿”(代码编号:H 35.8)患者的医疗组织和临床数据的评估而形成的。

¹ 俄罗斯联邦总统于2019年10月10日第490号命令《关于俄罗斯联邦人工智能发展》(与《2030年前国家人工智能发展战略》一并发布)。访问方式: https://www.consultant.ru/document/cons_doc_LAW_335184/1f32224a00901db9cf44793e9a5e35567a4212c7/。访问日期: 2023年11月22日。

² 俄罗斯联邦卫生部于2012年12月24日第1492n号命令《关于批准糖尿病视网膜病变和糖尿病性黄斑水肿初级医疗和卫生保健标准》。访问方式: <https://base.garant.ru/70344052/53f89421bbdaf741eb2d1ecc4ddb4c33/>。访问日期: 2023年11月22日。

结果记录方法

灵敏度和特异性是根据二元分类中的第一类和第二类误差推断出的诊断测试用于识别病人和健康人的统计量。

统计分析

样本量计算原则：在确定最小样本量时要考虑有效性标准、误差范围（置信区间与规定精度的乘积）。

材料的统计处理包括描述性统计方法、平均值计算、相对值计算、数学建模。通过数学计算和随后的对皮尔逊卡方检验的评估，对定性特征研究数据之间差异的统计意义进行了分析。在描述定量变量时，对其是否符合高斯分布（正态分布）进行了初步评估。

结果

研究对象（参与者）

研究对象是在眼球后段病变的防治观察期间为成年人提供眼科护理的组织系统。在内容分析的框架内，对22项规范性法案进行了分析。数据库是一个医疗信息系统，其中包括60000份使用计算机分析仪进行视网膜检查的记录、医学图像（图片）以及根据开发的二元分类器对检查结果的解释说明。

主要研究成果

在俄罗斯联邦，根据2011年11月21日第323-FZ号联邦法《关于俄罗斯联邦公民健康保护基本原则法》，医疗援助的组织提供包括：

- 1、根据按医疗援助类型组织医疗援助的规定；
- 2、根据经授权的联邦执行机构批准的、俄罗斯联邦境内所有医疗机构必须遵守的医疗救助流程；
- 3、根据临床建议；
- 4、考虑到联邦执行权力机关批准的医疗标准³。

此外，该法第2条第15款定义了“主治医生”一词。主治医生是指在观察和治疗病人期间负责组织和直接提供医疗服务的医生。主治医生的某些职能可根据批准的流程委托二级医务人员提供初级专科医疗服务，但不可能委托他人提供初级专科医疗服务，包括眼科医生专业标准中包括的医疗服务^{4,5}。护理人员在提供医疗服务时不能独立解释仪器检查的结果。只有在使用注册医疗设备的情况下，才有可能这样做。

护士使用医疗决策支持系统需要注册为医疗设备。如果由医生使用，则仍属于信息服务的法律范畴，因为对结果的解释、诊断和建议，包括在防治观察的框架内，仍属于主治医生的职权范围，与程序的法律地位无关。

利用专家方法，选择并描述了123个二元特征，以描述正常和病理视网膜黄斑区的结构。这些特征按以下部分分组：一般；玻璃体视网膜和视网膜界面；视网膜轮廓；视网膜厚度；视网膜结构；脉络膜。根据对具有相关教育背景和工作经验的专家进行的问卷调查结果显示了，在被诊断为“老年性黄斑变性”或“糖尿病性黄斑水肿”的患者中，有75%的医生仅将123种征兆中的26种征兆归为基础疾病临床病程恶化的预测因素（表1）。

所获得的特征直接或间接地表明了病理过程的发展，包括新生血管的形成，需要在三级医疗机构（包括联邦医疗机构）中提供专门的高科技医疗服务。这些特征也与临床建议和现代科学文献中描述的医疗服务和仪器诊断检查结果的解释相关[7, 8]。

二元分类器通过分类和分割被划分为适合用于训练人工神经网络的特征。使用60000张医学图像进行的人工神经网络训练被用于创建医疗决策支持系统，以便对眼球后段病变患者进行动态随访。使用“平衡准确率”指标对人工神经网络模型的准确率进行了评估，以正确解释数据中不同类别的分布情况。特征的平均平衡准确率为81%。

其他研究成果

医疗决策支持系统的开发版本可在公共领域获取：<http://retinadeepai.site/>。该系统可识别分析对象，这些对象是每个已开发特征的预测器，允许设置不同地图和模式的分析，包括在不同器械上获得的。推荐的分析模式是RetinaMap。该服务配备了符合人体工程学的直观界面，允许上传报告以作为医疗文件的附件。本服务不是医疗产品，而是信息服务；不存储、不处理患者的个人数据。该服务不做诊断，不提供诊断选择。它描述正常视网膜结构和病变发展情况，是眼科医生对患者进行动态观察的常规流程的一部分。

不良事件

未发现。

讨论

目前，全球正在开发几种利用人工智能早期诊断眼底病变的系统。例如，利用固定式和便携式眼底照相机获得的眼底图像检测糖尿病性视网膜病变早期征兆的系统：IDx-DR系统（商业名称为LumineticsCore，美国）、Retina.AI平台（Digital Vision Solutions LLC，俄罗斯）。

³ 2011年11月21日第323-FZ号联邦法《关于俄罗斯联邦公民健康保护基本原则》。访问方式：https://www.consultant.ru/document/cons_doc_LAW_121895/。访问日期：2023年11月22日。

⁴ 俄罗斯联邦卫生与社会发展部于2012年3月23日第252N号命令《关于批准在组织初级卫生保健和紧急医疗服务时，由医疗机构负责人向辅助医务人员或助产士分配主治医生在病人观察和治疗期间直接向病人提供医疗服务的某些职能的流程，包括处方和用药，其中包括麻醉药品和精神药物》。访问方式：<https://base.garant.ru/70170588/>。访问日期：2023年11月22日。

⁵ 俄罗斯联邦卫生与社会发展部于2017年6月5日第470n号命令《关于批准“眼科医生”职业标准》。访问方式：<https://docs.cntd.ru/document/436744741>。访问日期：2023年11月22日。

表1. 临床病程恶化的征兆

征兆	部门
黄斑区视网膜中度增厚（达500微米）	视网膜厚度
黄斑区视网膜明显增厚（超过500微米）	
发现到局灶性视网膜内水肿	视网膜结构
发现到弥漫性视网膜内水肿	
发现到视网膜内囊性水肿	
变化形式为小（最多50微米）的多发性囊肿	
变化形式为中等大小（50–150微米）的多发性囊肿	
变化形式为大（超过150微米）的多发性囊肿	
扫描到神经上皮的浆液性脱落	
扫描到神经上皮的浆液性裂缝样脱落	
扫描到视网膜色素上皮的浆液性脱落	
视网膜色素上皮脱落呈圆顶状	
扫描到视网膜色素上皮的平波状脱落	
扫描到视网膜色素上皮的扁平脱落	
扫描到视网膜色素上皮的table状脱落	
扫描到视网膜色素上皮的出血性脱落	
扫描到视网膜色素上皮的纤维血管脱落	
发现到双层症状	
高反射性不透明给底层造成“阴影”（视网膜下血肿）	
扫描到视网膜下积液	
扫描到视网膜内层的超反射焦点	
扫描到视网膜外层的超反射焦点	
扫描到视网膜色素上皮上的超反射焦点	
扫描到视网膜色素上皮中的超反射焦点	
扫描到视网膜色素上皮下的超反射焦点	
扫描到给底层造成“阴影”的超反射焦点	

此外，在医疗设备数据的自动分析方面也取得了一些进展。

- Retina.AI平台的目的是分析视网膜光学相干断层扫描图片，发现已宣布的综合症之一：视网膜下积液、视网膜内囊肿、视网膜色素上皮脱落、视网膜下高反光物质、视网膜外膜、视网膜葡萄胎、穿透性黄斑撕裂、片状黄斑撕裂、玻璃体黄斑牵引 (<https://www.screenretina.com/>)。因此，开发的目的是诊断病情，评估过程的动态。该项目尚未注册为医疗设备。
- Altris AI平台（美国）自动选择病理光学相干断层扫描并检测70多种病理和病理征象，包括视网膜上纤维化、视网膜内囊样积液、假性囊肿、弥漫性水肿、视网膜色素上皮纤维血管脱离、视网膜下高反射信号物质等病理 (<https://www.altris.ai/>)。该项目的任务是诊断病情（疾病）和培训医务人员。该开发项目已在生产国获得作为医疗设备使用的授权（美国食品药品监督管理局）。

我们正在开发的产品包含更多的评估功能（123项），其目标不是诊断，而是改变诊断和治疗过程的组织形式：将常规工作从医生转移到中层医务人员，缩短检查时间，增加医疗服务的可用性。

有必要修订护理人员职业标准，其中规定在对病人进行动态观察时使用人工智能信息服务。此外，还需要更新对眼后段病变患者进行防治观察的监管框架，包括将这种病变纳入卫生部于2023年3月15日第168n号命令《关于批准成人防治观察流程》中。

主要研究成果概述

眼球后段病变患者防治观察组织技术的方法论基础已经形成，描述视网膜的结构性分类器也已准备就绪，用于该病变患者防治观察的医疗决策支持系统也已开发完成。

对主要研究成果的讨论

俄罗斯联邦卫生部于2020年9月7日第947n号命令《关于批准以电子文件形式保存医疗记录的健康保

护领域文件管理系统组织流程》规定了使用电子医疗文件的流程。目前，俄罗斯已开发、批准并使用了大量结构化电子医疗文件。在联邦国家预算机构俄罗斯联邦卫生部《医疗组织和信息化中央研究所》的活动框架内，结构化电子医疗文件开发中心开展工作，通过制定、更新和升级结构化电子医疗文件的实施准则，确保完成俄罗斯联邦卫生部的任务，改善医疗领域的文件管理组织。所编写的参考书可作为使用计算机分析仪对视网膜进行仪器检查的医疗文件协议的基础。

结构化信息的积累将有助于改善已制定的医疗决策支持系统。监管框架的变化将有助于加快实施组织技术，利用基于人工智能的医疗决策支持系统对眼球后段病变患者进行防治观察。

研究局限性

研究结果被用于眼球后段病变患者的动态（防治）观察。研究结果不能用于视觉器官、附属器官和眼眶病变的初步诊断。

结论

在俄罗斯联邦的法律领域，没有可能将解释医疗检查结果的部分医疗职能委托给护理人员，这就需要完善视觉器官、附属器官和眼眶疾病概况的专业标准和监管框架。目前还没有统一的规则来创建包含

使用计算机分析仪解读视网膜检查结果的结构化电子医疗文件。我们开发的分类器可以（在60000张医疗图像的基础上）创建和训练一个医疗决策支持系统，该医疗决策支持系统作为一种信息服务，无需诊断即可改变动态观察过程的组织结构。病人路由的形成是我们开发的医疗决策支持系统的主要服务。如果出现临床症状恶化的迹象，就会将病人送往眼科医疗中心进行动态评估，并提供包括高科技在内的专门医疗服务。

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.

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, Kobayakova 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

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 // Национальное 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., Крошилин С.В. Теле-медицина 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. Ламбозо 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

AUTHORS' INFO

* **Aleksandr O. Lositskiy**, MD, Cand. Sci. (Medicine);
address: 17 Salmyshskaya street, 460047 Orenburg, Russia;
ORCID: 0000-0002-8716-6438;
eLibrary SPIN: 2044-3410;
e-mail: eyedoct@yandex.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

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

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

* Corresponding author / Автор, ответственный за переписку

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. Yazovskikh³, 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, Yazovskikh 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>

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>

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. Yuzlekbayev³

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”，“искусственный интеллект”（人工智能）、“машинное обучение”（机器学习）、“кальцификация сосудов”（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, Yuzlekbayev 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

论证

在过去二十年中，俄罗斯联邦循环系统疾病的发病率持续上升，从2000年到2019年增加了2.047倍[1]。血管钙化过程包括钙盐在动脉壁沉积，导致血管壁重塑[2]。内膜钙化是局灶性的，与动脉粥样硬化有关，而中膜钙化是弥漫性的，是糖尿病、外周动脉疾病和慢性肾脏疾病等疾病的发病机理基础[3]。放射检查方法是诊断血管钙化的金标准[4]。然而，由于数据量的不断增加和缩短诊断时间的需要，工作效率不可避免地会下降[5]。这些情况促使人们寻找新的方面来提高仪器诊断人员的工作质量。

人工智能的积极发展和引入临床实践为专家解决这些问题提供了机会[6]。根据对现有文献数据的分析，迄今为止，人工智能已被用于5种血管钙化的X射线诊断：冠状动脉钙化、胸主动脉钙化、腹主动脉钙化、颈动脉钙化和乳内动脉钙化。

该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

作者在电子数据库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”、“искусственный интеллект”（人工智能）、“машинное обучение”（机器学习）、“кальцификация сосудов”（血管钙化）。检索时间从相关数据库建立之初至2023年7月。作者独立分析了文章的标题

和摘要，然后提取了相关研究的全文。此外，还分析了相关研究的参考文献目录。

结果

研究被纳入综述的主要方法是比较临床医生和人工智能使用相同图像的诊断能力，然后评估准确率、速度和其他指标。

血管钙化的部位多种多样，这决定它们不同的预后价值。表1总结了不同部位血管钙化的预后价值。

冠状动脉钙化

弗雷明汉风险评分是心血管风险预测工具之一，该量表涉及年龄、性别和血压等风险因素的评估[7]。然而，一项为期7年的大型前瞻性研究报告称，通过电子计算机断层扫描（CT）诊断出的冠状动脉钙化可能会改善仅使用弗雷明汉风险评分得出的风险预测结果。M.H.Criqui等人在一项为期7.6年的随访研究中表明了，基于血管体积和密度的冠状动脉钙化严重程度评估具有良好的预后价值[8]。冠状动脉钙化体积与缺血性心脏病风险呈正相关，而冠状动脉钙化密度则呈负相关[8]。

钙化斑块密度和钙化面积的积分相乘即为冠状动脉钙化的程度。冠状动脉钙化总值是每个级别计算结果的总和。人们普遍认为，老年人是缺血性心脏病的主要风险人群[1]。然而，一项为期12.5年的研究表明了，即使冠状动脉钙化值较低，年龄在32至46岁之间的人罹患缺血性心脏病和死亡的风险也较高[9]。通过对这些研究结果的分析，我们可以得出结论，与冠状动脉钙化有关的信息在确定几乎所有年龄组的心血管事件风险方面都具有很高的预后价值。表2列出了冠状动脉钙化程度与不良心血管事件风险之间的关系。

表1. 不同部位血管钙化的预后价值

血管钙化类型	预后价值
冠状动脉钙化	- 冠状动脉粥样硬化严重程度的标志； - 根据弗雷明汉风险评分对心血管风险的评估； - 缺血性心脏病预示因素； - 肿瘤化疗中心脏毒性的标志
胸主动脉钙化	- 缺血性心脏病风险增加的标志； - 脑梗塞增加风险的检测； - 栓塞风险的检测
腹主动脉钙化	- 是否存在阻塞性缺血性心脏病的检测； - 缺血性心脏病无症状病程的预测； - 充血性心力衰竭的标志
颈动脉钙化	- 头颈部血管动脉粥样硬化的标志； - 中风风险的检测； - 年轻人脑血管不良事件风险的预测
乳内动脉钙化	- 女生发生心血管事件风险的检测； - 与慢性肾脏疾病、糖尿病和骨疾病的关系

表2. 冠状动脉钙化程度与不良心血管事件风险之间的关系

冠状动脉钙化评估	钙化风险
0	没有
1 - 10	低
11 - 100	中
101 - 400	高于中等水平
>401	高

胸主动脉钙化

众所周知，胸主动脉钙化广泛存在于高血压患者人群中[10]。此外，胸主动脉钙化与缺血性心脏病和死亡风险增加之间的关系也一再被揭示[10, 11]。根据一项包括2618人的研究，Y.Itani等人发现了，胸主动脉钙化是评估脑梗塞风险的有效手段[12]。R.Lee等人在对有心血管手术适应症的患者进行的研究中发现了，对胸主动脉钙化状态的术前CT筛查 TAC可识别高风险区域，降低主动脉栓塞和中风的概率[13]。因此，胸主动脉钙化的程度不仅可以预测心血管事件风险，还有助于发现脑血管病变。

腹主动脉钙化

一项针对58名患者的研究发现了，使用CT评估的腹主动脉钙化评分与冠状动脉钙化的严重程度相关。反过来，如果没有腹主动脉钙化，则可以排除缺血性心脏病[14]。此外，研究还表明了，腹主动脉钙化可作为无症状缺血性心脏病的额外诊断工具，也是充血性心力衰竭发生的独立风险因素[15, 16]。众所周知，腹主动脉钙化对骨系统具有重要的预后价值。Y. Z. Bagger等人进行了一项包括2662名绝经后健康女生的研究。研究结果表明了，腹主动脉钙化与股骨近端骨质疏松症的风险增加有关[17]。此外，P. Szulc等人的研究也证实了，腹主动脉钙化的存在与老年男生股骨骨折风险的增加相关[18]。

颈动脉钙化

颈动脉钙化是预测脑血管疾病的重要指标[19]。在不同种族群体中，颅内颈内动脉钙化是颅内高压的重要标志，与中风风险密切相关[19-21]。值得注意的是，一项包括约2000名患者的研究显示了，颅内颈内动脉钙化在年轻人中很常见。然而，尚不清楚年轻时的颅内颈内动脉是否与老年时发生的病理变化相似，从而是否能增加未来中风的风险[22]。

乳内动脉钙化

在一项包括213名患者的研究中，Z.Huang等人发现了，乳内动脉钙化与冠状动脉钙化和缺血性心脏病严重程度相关[23]。E.V.Bochkareva等人分析了4274例40-93岁女生的数字乳房X线图片。作者发现了，女生的年龄与乳内动脉钙化的存在之间存在统计学意义上的显著强相关性[24]。E.V.Bochkareva等人的其他

研究清楚地表明了，乳内动脉钙化与慢性肾脏疾病、糖尿病、脑血管疾病和骨矿物质密度紊乱的发生有关[25-27]。遗憾的是，女性患者对心血管疾病的认识不足，而心血管疾病是威胁女性健康最严重的疾病之一[28]。因此，鉴于乳内动脉钙化评估的可用性及其反映女性心血管风险的诊断价值，仪器诊断医生应充分重视这一问题。

血管钙化的仪器诊断困难

对俄罗斯联邦2014-2019年放射诊断服务发展的分析表明了，医疗图像的数量每年都在增长，仪器诊断部门的医生在8小时的工作日内每3-4秒钟就要解读一次图像[29]。一项对40名仪器诊断专家工作前后身体状况的研究显示了，工作一天后，注意力明显不集中，眼疲劳症状加重[30]。据报道，75%的仪器诊断专家医疗缺陷诉讼与诊断错误有关[31]。

准确判断血管钙化程度是一项艰巨的任务。钙化灶的形状多变，受各种疾病的影响。例如，各种CT改良技术被用于诊断冠状动脉钙化[32]，但它们需要额外的设备，这增加医疗机构的经济负担，也增加患者的辐射负担（如果使用标准方法进行诊断，则可减少辐射负担）。此外，放射科医生并不总是对图像上反映的血管钙化进行评估，而血管钙化可被用于间接评估冠状动脉钙化，但金标准是具有确定检查区域的心脏同步CT[33, 34]。

人工智能在动脉钙化评估中的作用

冠状动脉钙化

2007年，首次利用人工智能自动确定了冠状动脉钙化程度。为每个候选者开发了64个特征，然后采用近邻聚类法，这是一种用于自动对象分类或回归的度量算法，准确率达到73.8%[35]。随后几年，包括空间和几何方法在内的各种特征设计方法得到了积极探索[36-38]。由于在非对比CT图像中选择对象会造成技术上的困难，利用CT图像获得的信息与冠状动脉钙化检测进行配准已成为一种较为流行的方法[39-41]。为确定冠状动脉钙化，通常使用心电图同步来获取舒张期图像，然后通过“拼接”图像进行重建。使用支持向量机的算法灵敏度达到98.9%，预测值达到94.8%[42]。这种机器学习算法在2016年之前一直被积极使用，但由于需要人工控制，其应用存在一定的困难[42]。

为了进一步提高效率，人们选择了具有深度学习功能的人工神经网络作为主要方案[43]。起初，深度学习的性能并不令人满意，但通过对人工神经网络的不断改进，研究人员得以提高效率，实现准确、自动评分[44-51]。

B.D.de Vos等人在一项关于冠状动脉钙化测定的研究中发现了，使用深度学习获得的结果与人工计算的结果几乎相同，而Agatston指数（临床实践中钙计数的金标准CT方法）的测定不到0.3秒[52]。

U-Net算法是对人工神经网络的扩展，旨在利用更少的资源实现更高效的学习[53]。N.Gogin等人 在研究中证实了基于U-Net架构的深度学习的有效性，其性能非常接近其他算法[46]。在86%的情况下，U-Net能

正确地对风险进行分类。值得注意的是,使用U-Net可以直接输入图像,而不会丢失像素信息[49]。

与无心电图CT相比,心电图同步CT的全球应用较低[54]。如果提高无心电图冠状动脉钙化信息的可靠性,就有可能减少CT检查的次数,从而降低经济成本和辐射暴露[55]。大量干扰和伪影的存在大大降低使用无心电图CT人工测定冠状动脉钙化的准确率[56]。

人工智能在使用无心电图CT诊断冠状动脉钙化方面发挥了重要作用。I. Isgum等人早在10多年前就发现了,使用低剂量胸部CT进行Agatston评分,机器学习算法的准确率可达82.2%[57]。许多研究人员试图降低干扰和伪影水平,并减少非钙化成分(支架)对诊断的影响。他们开发的深度学习算法提高了低质量图像的价值[58, 59]。Z. Sun等人证实了,深度学习算法将低剂量CT的信噪比提高了27.7%,由于消除了伪影,冠状动脉钙化检测的特异性提高了41%[60]。重要的是,无心电图CT解释正确率仅为70%;然而,使用人工智能和人工分析的结果之间的相关系数为0.923[56]。

在B. Yacoub等人进行的另一项研究显示了,在非对比胸部CT上检测冠状动脉钙化时,使用人工智能获得的灵敏度、特异性和曲线下面积(AUC)均优于人工结果。这表明,人工智能应用于无心电图CT的性能可能优于人工评估[34]。此外,一项研究在4个不同的中心证实了使用无心电图CT的人工智能的有效性。在所有样本中,均获得了较高的灵敏度和阳性预测值,从而提高了所得结果的质量[61]。应该指出的是,目前,基于无心电图CT的冠状动脉钙化诊断中应用人工智能是一种可靠的数据评估方法。

值得注意的是,研究人员已开始将人工智能功能应用于其他设备上的冠状动脉钙化诊断,例如分析胸片[62]。P. I. Kamei等人利用深度人工神经网络对胸片上的钙总量进行了分类,证明可以减少对一些患者的CT使用[63]。在这项研究中,检测冠状动脉钙化的前后位和侧位投影图像的AUC分别达到0.73和0.7。此外,一项研究提出了一种神经网络,可在数秒内分析有创冠状动脉造影时获得的图像,并以0.802的F1系数检测出冠状动脉钙化[64]。

胸主动脉钙化

与冠状动脉钙化相比,CT检测胸主动脉钙化的准确率与心脏收缩的强度无关[65]。例如, I. Isgum等人使用k-近邻法检测出97.9%的胸主动脉钙化,这与人工检查的结果相关[65]。近年来,深度学习的使用使得冠状动脉钙化和胸主动脉钙化的检测得以同时进行[66]。S. G. M. van Velzen等人也持类似观点,他们将所述方法应用于不同类型的CT扫描(包括冠状动脉钙检测的CT、低剂量胸部CT和正电子发射CT),类内相关系数从0.68到0.98不等[67]。值得注意的是,在一项使用卷积神经网络检测胸主动脉钙化的研究中,灵敏度达到了98.4%,不仅可以区分主动脉升段和降段以及主动脉弓的胸主动脉钙化,还可以确定风险的严重程度[68]。因此,使用人工智能自动评估冠状动脉钙化和胸主动脉钙化是放射科医生工作中不可或缺的一部分。

腹主动脉钙化

由于深度学习的进步,腹主动脉钙化自动检测的可能性已经实现,并在两项研究中得到证实[69, 70]。双能X线吸收测量法是一种评估骨折风险的诊断方法。这种方法的使用越来越多,为自动评估腹主动脉钙化提供了可能,但由于技术上的困难,它并未用于常规腹主动脉钙化检测。S. Reid等人使用基于显象测密度法的卷积神经网络对腹主动脉钙化进行了分类,结果与人工获得的结果高度一致,Kappa评分为0.71[69]。值得注意的是,与双能X线吸收测量法相比,CT在主动脉钙化定量评估方面具有明显优势。P. M. Graffy等人利用腹部CT成功对9000多名患者进行了腹主动脉钙化自动检测,他们解释了原因是Mask Region-based Convolutional Neural Network的使用[70]。基于定量数据,该研究还评估了腹主动脉钙化的患病率,从而提高了人工智能的重要性。

总之,可以利用人工智能对腹主动脉钙化进行自动定量评估,但可用数据量非常有限。

颈动脉钙化

使用人工智能的CT可以诊断颈内动脉颅外和颅内部分的钙化[71, 72, 73]。G. Bortsova等人研究中使用了4个结构类似于U-Net的深度学习网络,其颅内颈内动脉钙化检测的准确率高于人工评估,灵敏度为83.8%,预测值为88%[73]。人工评估颅内颈内动脉钙化需要仔细分析,容易出错,而且容易出现类似结构(如骨性钙化)的风险。因此,深度学习所表现出的高准确率就显得尤为重要。

磁共振成像可检测出颈动脉钙化与其他血管钙化之间最明显的差异[71]。在早期的研究中,使用磁共振成像检测钙化的准确率较低[71]。然而,SNAP(simultaneous non-contrast angiography and intraplaque hemorrhage)的使用提高了利用磁共振成像识别钙化的能力。使用SNAP时,所有信号均由反转脉冲反转,然后进行T1加权反转恢复,并使用双梯度回波进行质子密度加权控制扫描,这在颅内血管和颈椎成像方面效果极佳[74]。虽然SNAP能成功检测钙化,但它会受到运动伪影的影响,而且研究时间相对较长。使用Goal-SNAP和快速SNAP可以解决这一问题[75, 76]。在本研究中,随机森林法等机器学习算法在钙化检测方面与人工神经网络相似,但深度学习在血管成分分割方面可能更有效,这需要进一步研究。

乳内动脉钙化

乳内动脉钙化可在乳房X线图片上看到,但钙化的表现形式千变万化。它们可以分叉、重叠、截断,强度也各不相同[77]。这种复杂性给人工乳内动脉钙化定量评估带来困难。

乳房摄影术是一种用于乳腺癌筛查的放射诊断方法,自2012年起被纳入预防性体检和健康检查的范围。根据俄罗斯联邦卫生部的规定,这种检查的频率每年都在增加[78]。

关于这个问题,很多学者都考虑过深度学习的应用。有人建议将乳房X线图片切成若干部分,由于直

表3。人工智能在5种血管钙化诊断中的应用结果比较

血管钙化类型	研究数量	射线摄影的应用	电子计算机断层扫描的应用	是否使用磁共振成像	深度学习的应用
冠状动脉钙化	大	有	有	没有	像素和端到端的深度学习与生成对抗网络相结合，可减少噪声和伪影，从而使冠状动脉钙化自动评估更加稳健，并可对结果进行可靠的评估
胸主动脉钙化	中等	没有	有	没有	深度学习可自动检测胸主动脉钙化和颈动脉钙化，从而评估不同主动脉部位的结果
腹主动脉钙化	小，需要更多研究	有	有	没有	掩码区域卷积神经网络等深度学习方法可使用双能X线吸收测定法和电子计算机断层扫描对腹主动脉钙化进行精确定量评估
颈动脉钙化	小，需要更多研究	没有	有	有	深度学习的效果似乎接近机器学习的效果，并优于人的能力，还能使用磁共振成像技术
乳内动脉钙化	中等	有	没有	没有	U-Net、SCU-Net、DU-Net和其他先进的深度学习系统有助于乳内动脉钙化检测

注：SCU-Net——简单上下文U网络；DU-Net——深度U网络。

接输入的数据量很大，这一点很有必要[53]。一个12层的卷积神经网络将乳内动脉钙化检测描述为一个二级问题[28]。虽然它能成功区分是否存在乳内动脉钙化，但其结果的定量评估不够准确[28]。此外，由于需要分别处理每个站点，数据分析和处理速度相当慢。随后，研究人员考虑到上述缺点，对卷积神经网络进行了改进，提出使用简单上下文U网络（SCU-Net）和深度U网络（DU-Net）[33, 53]。SCU-Net是U-Net的简化版，它克服乳内动脉钙化只占图像的不到1%，从而产生大量数据、影响系统有效训练的挑战。DU-Net也避免这一问题，大大提高卷积神经网络的效率，准确率达到91.47%，灵敏度达到91.22%[53]。

总之，用于乳内动脉钙化自动检测的深度学习已经达到了很高的水平，但在这一领域还没有可靠的公开可用的统一数据集，因此需要在这方向开展进一步的研究。

讨论

如上所述，人工智能可以通过进行预筛选和提高数据处理效率，促进和改善仪器诊断医生在血管钙化方面的工作。

人工智能应用于放射诊断的准确率与人工智能算法和图像特征有关。机器学习和深度学习算法的性能已取得显著进步，这有助于提高这些技术的诊断价值。随着成像技术的发展，图像质量不断提高，这对诊断性能产生了积极影响。人工智能能力与训练所需的高质量数据库相关联，这也有助于创建公开可用

的数据库或测试平台。因此，未来工程师和临床医生应根据人工智能算法本身和图像质量，努力发展人工智能诊断能力。

值得注意的是，虽然人工智能在5种类型的血管钙化中显示出令人满意的效果，但它在肾动脉钙化等类型的钙化中具有潜在价值，而肾动脉钙化对动脉高血压和蛋白尿的预后价值已得到证实[79]。同时，专门针对腹主动脉钙化和颈动脉钙化的研究数量很少，这引起人们对其研究的更大兴趣。人工智能诊断各种类型血管钙化的效果比较见表3。

结论

人工智能在血管钙化诊断方面表现出色。除了提高准确率和效率外，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能够协助仪器诊断人员自动检测血管钙化的水平。未来，人工智能能力可能会促进放射学的有效发展。

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.

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-Z081
- 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: KPXLV 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):4–11. EDN: DTCAWX 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.athoracsurg.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
- Szulc 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

26. 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
27. 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
28. 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
29. 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):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, Alkadhi 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 Debloating 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, Isgum 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

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., Говорукина А.А., Бурыкин Ю.Г., Афинева 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: KPXLV 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. Йео 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: DTCAXX 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 маркера 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 мультиспиральной 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., Alkadi 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., Išgum 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. Guilenea 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

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: chupakhina@bk.ru

ОБ АВТОРАХ

* Нуркаева Адиля 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: chupakhina@bk.ru

* Corresponding author / Автор, ответственный за переписку

Natalia A. Yakovenko;

ORCID: 0009-0005-6726-9623;

eLibrary SPIN: 4415-2236;

e-mail: tigris2011@yandex.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. Yazovskikh;

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

Яковенко Наталья Александровна;

ORCID: 0009-0005-6726-9623;

eLibrary SPIN: 4415-2236;

e-mail: tigris2011@yandex.ru

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

Юзлекбаев Азат Флюрович;

ORCID: 0009-0002-8799-4732;

eLibrary SPIN: 4812-3213;

e-mail: ztl5@rambler.ru

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. Vladzmyrsky^{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, Vladzmyrsky 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>

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>

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

绪论

在过去几年中,放射诊断发生了一系列重大变化。特别是,基于计算机视觉的技术已被积极用于解读计算机断层扫描(CT)图片,以改善和加快疾病诊断,减轻医务人员的负担[1-3]。一些分析胸部CT图片的人工智能算法已经证明,某些疾病的诊断准确率很高(ROC曲线下面积达到0.88)[3]。

计算机视觉在腹部病理诊断方面也在积极发展。在过去五年中,发表在PubMed资源上的有关这一问题的研究数量增加了12倍(从2018年的34篇增加到2022年的411篇)。科学研究数量的快速增长可归因于越来越多的人可以接受CT扫描检查,可检测疾病的清单相当庞大且不断增加,以及使用CT扫描验证疾病的准确性较高。

目前,已有基于计算机视觉技术的现成解决方案,可以在腹部和腹膜后CT扫描图片中检测出肝肾肿块以及泌尿系统结石等常见病症[4]。

这些决定基于算法,根据其功能可分为两类:

- 1、识别(分割)器官及其病理;
- 2、进行病理分类。

同时,所述解决方案显示出不同程度的诊断准确性,这在一定程度上可能是由于深度学习网络和计算机视觉算法的基础架构造成的。基于卷积神经网络的深度机器学习架构目前在分类领域最为流行[5]。

本综述致力于研究计算机视觉算法的诊断准确性,这些算法旨在检测CT图片上的肝肾肿块以及泌尿系统结石,具体准确性取决于这些算法的目的(分割或分类)以及其基础架构。

搜索方法

我们进行了一项分析性研究:选择性文献综述,重点关注为初级诊断设计的算法,这些算法被用于肝肾肿块和尿石病等常见疾病。

虽然腹部和腹膜后CT可以检测到的其他一些肿瘤(如胰腺肿瘤)也很常见,但在本综述中,作者只关注肝肾肿块和泌尿系统结节。关于使用计算机视觉检测这些解剖区域内其他器官肿瘤的研究较少或没有。

通过PubMed互联网服务(访问日期:2023年4月31日)使用关键词组合搜索科学出版物:[“Deep Learning”, “Neural Network”, “Artificial intelligence”]+[“Liver tumor”, “Kidney tumor”, “Hepatocellular carcinoma”, “Kidney Stone”]+“Computed Tomography”。

此外,还通过关键词“Искусственный интеллект”+“компьютерная томография”(“人工智能”+“计算机断层扫描”)在科学出版物电子图书馆和俄罗斯科学引文索引的国家信息和分析系统eLibrary(访问日期:2023年4月31日)中搜索了2019年至今的研究,但没有发现直接致力于深度学习算法诊断腹部和腹膜后病理的著作。

从使用PubMed互联网服务找到的研究中,分析包括使用计算机视觉算法对腹部和腹膜后CT图片上的

靶向病理进行分割和分类的论文,这些论文描述了深度学习算法的架构,并使用其中一个指标展示了算法操作的结果:在分割和准确性任务中使用戴斯相似性系数,在分类任务中使用F1分数或ROC曲线下面积(AUC)[6]。

搜索深度限于2020年1月1日至2023年4月24日。

结果

因此,有21篇论文被纳入本综述,其数据见附录1。对所选论文进行了架构分析,并对诊断指标进行了评估。与未纳入分析的其他公开论文进行了比较。

肝脏肿块

目前诊断肝脏肿块信息量最大的方法是对比增强CT和磁共振成像(MRI)[7]。同时,CT与MRI相比有许多优势,如设备可用性、专家培训、检查速度和成本效益[8]。由于无造影剂检查的信息量较低,在怀疑肝脏肿块时,使用对比增强是标准方法。然而,在其他一些疾病中,大量的腹部CT检查都是在没有造影剂的情况下进行的。计算机视觉算法在原始CT图片上检测肝脏肿块的能力可用于筛查这种病变[9-11]。

U-Net架构及其修改(特别是ResNet块的使用)最常用于肝脏及其肿块的分割任务,显示出相当高的诊断准确性。H. Rahman等人在使用ResUNet完成的肝脏及其肿块分割任务范围获得了最高性能:戴斯相似性系数为0.99,准确率为99.6%[12]。肝脏肿块分割的示例见图1。

与使用体素(三维图像)的算法相比,使用像素(二维图像)进行分割的算法显示出更好的诊断指标[12-18]。

在肝脏肿块分类任务中,基于体素的算法具有更好的诊断性能。同时,我们已经可以看到,这些算法可以将肿块分为良性和恶性,而且可靠性很高(准确率达到82.5%)。目前,确定恶性肿瘤具体类型的准确率较低,仅为73.4%[19, 20]。

尽管深度机器学习得到了发展和广泛应用,但值得注意的是,一些经典的机器学习算法(如支持向量机——support vector machine, SVM)在对肝脏肿瘤进行分类时也显示出很高的诊断指标:准确率达到84.6%[19, 21]。

如今,在莫斯科市卫生局诊断和远程医疗技术科学实践临床中心的基础上,正在开展一项工作,以创建一种计算机视觉算法,利用对比度增强技术分割和区分病理肝脏肿块的类别。这项工作的一个示例见图2。

肾脏肿块

在27-50%的病例中,肾脏肿块是无症状的,是偶然发现的[22]。CT不仅能确定肿块的位置和大小,还能评估肿块与肾盂和主要血管的关系。

在所分析的研究中,U-Net架构及其修改版最常用于解决肾脏及其肿块的分割问题。目前,使用三




图1。一种算法对肝脏肿块进行分割的示例。

维U-Net架构进行肾脏分割的戴斯相似性系数达到0.97[23]。使用相同的架构，在肾肿瘤（0.84）和肾囊肿（0.54）的分割任务中获得了最高的戴斯相似性系数。因此，肾脏肿块的分割准确度仍然低于肾脏本身的分割准确度。

此外，值得注意的是，基于体素架构的CT切片上肾脏及其肿块的分割诊断准确率并不比基于像素的经典算法差[23-26]。

其他架构（如EffectiveNet）在分割肾脏及其肿块时也显示出较高的戴斯相似性系数值（高达0.95）[27, 28]。肾脏肿块分割的示例见图3。

经典机器学习算法和基于深度机器学习的算法[24, 26, 29-31]都被用于解决肾脏肿块分类问题。Swin Transformers架构的准确率最高（99.3%）[29]。

经典机器学习算法和前向传播架构在数据限制条件下表现良好[26]。正如在分割肾脏及其肿块的任务




图2。一种算法对对比增强计算机断层扫描图片进行肝脏肿块分割的示例。




图3. 右肾肿块的分割示例。

中,使用体素的架构与使用像素的架构在解决分类问题上同样准确[31]。

尿石病

尿石病是第二大最常发现的泌尿系统疾病[32]。与此同时,在俄罗斯联邦的所有地区,尿石病的发病率及其在成年人口中的流行率都在稳步上升。根据 N.Gadzhiev 等人的研究,15年间,尿石病的流行率增加了35.4%,发病率增加了16.2%[33]。

在尿石病的诊断中,腹膜后CT是金标准,可确定不透射线的结石的位置、形状、大小和数量,灵敏度高达96%,特异性高达100%[34]。

所分析的文章显示,检测结石的准确率直接取决于结石的大小。基于卷积神经网络的算法的准确率随着大小的增大而提高[35, 36]。因此,小于1cm的结石检测准确率为85%,1至2cm的结石检测准确率为89%,大于2cm的结石检测准确率为93%。

基于变换器 (Swin Transformers) 的算法是迄今为止检测泌尿系统结石准确率最高 (98%) 的算法 [29]。一种算法检测结石的示例见图4。

使用计算机视觉算法诊断尿石病时,在检测小结石时可能会遇到困难,因为肾动脉壁上会存在小的动脉粥样硬化斑块,其密度与尿酸盐结石相对应[36]。




图4. 一种算法检测结石的示例。

与此同时,深度机器学习和计算机视觉领域的现代技术使得在低辐射照射下检测3mm大小的结石成为可能,而5mm或更大的结石被认为具有临床意义[37]。

确定结石类型是影响后续治疗策略的最重要因素之一[35, 37]。关于确定术后预后(尤其是无复发病程),以及基于机器学习技术确定结石类型的研究使用许多基于CT的不同特征[38–41]。一些关于使用双能量CT(Dual-Energy CT, DECT)的研究表明,可以使用这种成像方法来确定结石的化学成分[42, 43],但这种方法有许多局限性,首先,这种方法在常规实践中的应用有限[44]。

Y.Cui等人的研究表明了,利用高度专业化的卷积神经网络,可以使用S.T.O.N.E.肾结石评价系统评估结石,其结果与放射科医生的结论相当[45]。这种方法还能估计患者的预后因素[46]。

讨论

在许多论文中,研究都是在公共数据集上进行的,如LiTS、KiTS' 19、3D-IRCADb等,这些数据集主要包含对比检查。在使用自己CT图片的研究中,数据集也主要包含对比检查或混合数据。

根据所分析的出版物,目前开发的深度学习算法可以在CT图片上实现高精度的肝脏分割(最大戴斯相似性系数为0.99,平均为 0.92 ± 0.09)和肾脏分割(最大戴斯相似性系数为0.97,平均为 0.94 ± 0.02) (见附录1)。

在肝脏分割任务中,像素算法的诊断准确性指标值最高(最大戴斯相似性系数为0.99,平均为 0.97 ± 0.01),而在肾脏分割任务中,基于体素的算法并不比基于像素的算法差。这可能是由于这些实质器官的大小和密度不同,以及算法开发的历史特点造成的。使用体素需要更高的性能,而这种计算系统的广泛使用是最近才出现的,它们现在已有了研究中心正在开发的大量改进的、基于像素的算法基础。

肝肾肿块的分割准确度低于这些器官本身的分割准确度。肿块分割不准确的主要原因是分割不完全。肿块边界的正确确定取决于肿块的生长类型和结构,因此外生性异质肿块的分割效果最好[23]。简单等密度囊肿、血管瘤等的分割准确度低也与此有关[20]。

在使用分割算法之前对数据进行预处理,可以部分解决这个问题[27, 28]。K.Yildirim等人的研究表明了,利用深度学习算法分析其他CT切片(如矢状切面或冠状切面)也能提高病理检测的准确率[47]。

根据已分析的文献,使用体素而非像素进行肿块分类更为合理,因为肿块结构的类型可用于确定其性质[19, 26, 31]。基于深度学习的技术可以高精度地将腹部肿块分为良性肿块和恶性肿块[19, 20, 31]。

分割的完整性对后续分类的正确性至关重要。目前,可以结合使用二维算法进行分割和三维算法进行分类[19, 24]。此外,将深度学习算法与经典机器学习算法(包括梯度提升)结合使用,可以改善诊断指标[19]。在所分析的作品中,可以区分出这些算法组合的两种变体。L.Yang等人 and M.Shehata等人

提出通过算法方法形成特征,并将其用于前向传播网络[30, 31]。E.Trivizakis等人 and X.L.Zhu等人则相反,他们从深度学习网络中形成特征,并使用经典机器学习算法对其进行分类[19, 26]。

同样重要的是将变换器架构用于肿块分类,但其使用受到训练数据量的限制。在使用变换器架构时,要想获得较高的指标,需要比超精确神经网络多好几倍的训练数据[29]。

所分析的论文使用标准指标来评估深度学习算法的质量,但各篇论文的研究方法各不相同,因此很难对诊断准确性进行充分的比较评估。另一个限制因素是,大多数作者未能为诊断准确性参数的所得值提供95%的置信区间,因此无法评估使用不同神经网络架构和方法所得指标之间差异的可靠性。引入标准化的评估方法可能有助于找出效果更好的算法[48]。此外,有必要指出的是,我们所分析的一些研究的样本有限。

深度学习算法的另一个用途是提高低剂量检查中获得的CT图片的质量。例如,F.R.Schwartz等人建议在双能量CT检查时使用深度学习算法来进行数据插值和重建[49–51]。有了这种方法,就有可能在低辐射剂量下获得高能量图片。

因此,计算机视觉算法目前在检测CT图片上的泌尿系统结石以及肝肾肿块方面已经显示出很高的诊断准确性参数。下一步的任务是将计算机视觉融入医疗机构的工作中,以改进和加快疾病诊断,减轻医务人员的负担。还需要进一步开展更大规模、前瞻性和详细的研究,这些研究要与基于人工智能的腹部肿块筛查软件的功效评估有关,而且需要对这些研究进行定性和定量评估,并对其结果进行验证。

结论

现有的用于腹部和腹膜后CT评估的计算机视觉系统不仅能有效检测肝肾肿块以及泌尿系统结石,还能高精度地确定其定量和定性特征。进一步的技术发展将促进三维深度学习算法的发展,提高其诊断准确性,从而获得更可靠的结果,特别是在多类分类任务中。使用体素数据可以更准确地确定病理类型,因为在这种情况下,算法可以在三维空间而不仅仅是在单个切片的平面上完整地分析病理形成。

今后可对由此产生的计算机视觉数据进行更深入的评估,以确定对比增强检查各阶段的“价值”。提高CT图片质量的方法开发将允许根据特定目的只扫描特定阶段(如动脉和排泄),从而减少患者接受的有效辐射剂量。

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.

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, Vladzimirsky 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. AI 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, Vladzimirsky 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 U-Net 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.IBJU.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;(3915603231162881). 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, Bozdog 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

СПИСОК ЛИТЕРАТУРЫ

- Ильяшенко О.Ю., Лукьянченко Е.Л. Возможности применения компьютерного зрения для аналитики данных в медицине // Известия Саратовского университета. Новая серия. Серия : Математика. Механика. Информатика. 2022. Т. 22, № 2. С. 224–232. EDN: MCSCLKQ doi: 10.18500/1816-9791-2022-22-2-224-232
- 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: JMMMD F doi: 10.23670/IRJ.2022.121.7.038
- Гусев А.В., Владзимирский 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
- 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
- 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
- Клинические испытания систем искусственного интеллекта (лучевая диагностика) / под ред. Ю.А. Васильева, А.В. Владимировского, Д.Е. Шаровой, и др. Москва : ГБУЗ «НПКЦ ДиТ ДЗМ», 2023. EDN: PUIJLD
- 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
- Patel B.N., Boltyenkov 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
- 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
- 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
- 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
- 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
- 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
- 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
- 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
- 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
- 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
- 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
- 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
- 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
- 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
- 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
- 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
- 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
- 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.IBJU.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., Bozdogan 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

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

Yuriy A. Vasilev, MD, Cand. Sci. (Medicine);
ORCID: 0000-0002-0208-5218;
eLibrary SPIN: 4458-5608;
e-mail: npcmmr@zdrav.mos.ru

Anton V. Vladzimirskyy, 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

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

Васильев Юрий Александрович, канд. мед. наук;
ORCID: 0000-0002-0208-5218;
eLibrary SPIN: 4458-5608;
e-mail: npcmmr@zdrav.mos.ru

Владзимирский 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

Шихмурадов Давид Уружбекович;
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

* Corresponding author / Автор, ответственный за переписку

附录1

表1。通过成像方法检测腹部病理的深度机器学习算法的架构和诊断指标

1	2	3	4	5
临床任务	作者, 年份	测试样本量	所用架构	宣布的诊断准确性指标
肝脏肿块及其结构的分割	M. Maqsood等人, 2021年[13]	4个检查	Res blocks后使用Multi-scale parallel convolution blocks的ResUNet	肝脏分割: - 戴斯相似性系数: 0.77; - 准确率: 93%
	R. Z. Khan等人, 2022年[14]	3个检查 (Dicadb) 19个检查 (LiTS) 4个检查 (Silver07) 1个检查 (Chaos)	ResUNet。基本块有三个Conv2D串行层, 可扩展卷积核 (三种扩展速度, 即1、2和4)	1、肝脏分割, 戴斯相似性系数: - 在Dircadb数据集上: 0.97; - 在LiTS数据集上: 0.97; - 在Silver07数据集上: 0.97; - 在Chaos数据集上: 0.95。 2、肝脏肿块的分割, 戴斯相似性系数: - 在Dicadb数据集上: 0.92; - 在LiTS数据集上: 0.87
	H. Rahman等人, 2022年[12]	4个检查	依次使用ResUNet对肝脏进行分割, 然后使用另一个ResUNet获取的数据对肿块进行分割	肝脏及其肿块的分割: - 戴斯相似性系数: 0.99; - 准确率: 99.6%
	A. Affane等人, 2021年[15]	1个检查	3D U-Net的三种修改: 1、3D U-Net, 经典网络 2、3D MultiRes U-Net。在Skip Connection之前使用Resolution Path块。在Conv块内: 三个大小为 $3 \times 3 \times 3$ 的链接3D卷积 (第一个有32个滤波器, 后两个各有16个滤波器), 与通过Conv3D (大小为 $1 \times 1 \times 1$, 64个滤波器) 的输入数据进行合并、归一化和求和。然后进行S型激活 3、3D Dense U-Net: 在每个Conv层之后进行残差连接式合并	肝脏分割, 戴斯相似性系数: - 0.86 - 3D MultiRes U-Net; - 0.84 - 3D Dense U-Net; - 0.73 - 3D U-Net
	J. Wang等人, 2023年[17]	8个检查 (Dicadb) 15个检查 (LiTS)	3D MAD-UNet: 在所有解码器级别中使用Long-Short Skip Connection (LSSC) 和Attentionmodule (AM)	肝脏肿块的分割, 戴斯相似性系数: - 0.96 - LiTS数据集上的3D U-Net+LSSC+MA网络; - 0.96 - Dicadb数据集上的3D U-Net+LSSC+MA网络; - 0.92 - LiTS数据集上的3D U-Net网络; - 0.89 - Dicadb数据集上的3D U-Net网络

续表1

1	2	3	4	5
	K. G. Kashala等人, 2020年[18]	250个检查	修改后的SqueezeNet, 是在第2、4、6和8个块之后添加遍历, 并在expand合并之前使用Conv2D (1×1) 的模型	- 准确率: 81.8%; - F1分数: 0.80
根据疾病分类学的肝脏肿块分类	J. Zhou等人, 2021年[20]	154个检查	使用2.5D Faster R-CNN进行分割; 使用3D ResNet-18 (基于Conv3D的修改) 进行分类	- 准确率: 82.5% (确定良性/恶性肿瘤时); - 准确率: 73.4% (确定6种病理之一, 即肝细胞癌、胆管癌、转移瘤、血管瘤、增生、囊肿)
	M. Rela等人, 2022年[21]	14个检查	支持向量机、k-邻近算法	1、支持向量机: - 准确率: 84.6%; - F1分数: 0.80 2、k-邻近算法: - 准确率: 76.92%; - F1分数: 0.76
肾脏和肿块的分割	Y. Ding等人, 2022年[25]	30个检查	- U-Net - V-Net, 是指使用处理3D图片的ResNet块的修改	肾脏分割: 1、左肾的戴斯相似性系数: - 0.93 - U-Net网络; - 0.92 - V-Net网络 2、右肾的戴斯相似性系数: - 0.91 - U-Net网络; - 0.92 - V-Net网络
	Z. Lin等人, 2021年[23]	66个检查	3D U-Net	1、肾脏分割: - 戴斯相似性系数: 0.97 2、肾脏肿块分割: - 戴斯相似性系数: 0.84 3、肾囊肿分割: - 戴斯相似性系数: 0.54

续表1

1	2	3	4	5
肾脏和肿块的分割	C. H. Hsiao等人, 2022年[27]	90个检查	U-Net, 其中ResNet-41或EffectiveNet的架构被用作编码器模块	肾脏分割: 1、戴斯相似性系数 (数据经预处理, U-Net带有编码器): - 0.96 - EfficientNet-B7; - 0.95 - ResNet-41; - 0.95 - EfficientNet-B4; - 0.95 - EfficientNet-B4, 预训练 2、戴斯相似性系数 (数据未经预处理, U-Net带有编码器): - 0.95 - EfficientNet-B4, 预训练; - 0.93 - ResNet-41; - 0.29 - EfficientNet-B4; - 0.27 - EfficientNet-B7 3、肾脏肿块的分割: 戴斯相似性系数 - 0.41 (EfficientNet-B5)
	C. H. Hsiao等人, 2022年[28]	56个检查 (KiTS19)	EffectiveNet-B5 (编码器); Feature pyramid network (解码器)	肾脏及其肿块的分割: 戴斯相似性系数: 0.95
根据疾病分类学的肾脏和肿块的分割和分类	M. H. Islam等人, 2022年[29]	~1000张图片	6个架构: - 修改后的VGG16; - Inception v3; - ResNet50; - EANet; - Swin Transformers; - CCT	肾脏肿块的分类: 1、VGG16结构: - 准确率: 98.2%; - F1分数平均值: 0.98; - AUC平均值: 0.99 2、Inception v3架构: - 准确率: 61.6%; - F1分数平均值: 0.59; - AUC平均值——0.85 3、ResNet50架构: - 准确率: 73.8%; - F1分数平均值: 0.74; - AUC平均值: 0.93 4、EANet架构: - 准确率: 77.0%; - F1分数平均值: 0.77; - AUC平均值: 0.96 5、Swin Transformers架构: - 准确率: 99.3%; - F1分数平均值: 0.99; - AUC平均值: 0.99 6、CCT架构: - 准确率: 96.5%; - F1分数平均值: 0.97; - AUC平均值: 0.99

续表1

1	2	3	4	5
	N. Toda等 人, 2022年 [24]	132个检查	用于肾脏分割的2D U-Net; 用于肿块分割和分类的3D U-Net	肾脏肿块分类: - 准确率: 87.5%; - AUC: 0.93
根据疾病分类学的肾脏和肿块的分割和分类	X. L. Zhu等 人, 2022年 [26]	20个检查	FS-Net: 原始数据通过预训练的3D U-Net运行, 得到的掩码与原始数据相结合, 再通过预训练的3D U-Net运行。根据得到的掩码, 制作出肾脏和肾脏区域的分割数据。对分割后的数据进行纹理分析, 以提取特征。肾脏区域通过预训练的3D ResNet来提取特征。获得的特征被用于支持向量机	1、肾脏分割: - 戴斯相似性系数: 0.97 (KiTS19) ; - 戴斯相似性系数: 0.97 (自有数据集) 2、肾脏肿块分割: - 戴斯相似性系数: 0.79 (KiTS19) ; - 戴斯相似性系数: 0.77 (自有数据集)
肾脏肿块及其特点的分类	L. Yang等 人, 2022年 [30]	120个检查	使用pyradiomics库从人工分割的有肿块的肾脏中提取特征。特征通过前向传播网络运行	肾脏肿块分类, AUC: - 0.76 - 在原生期; - 0.79 - 在皮质髓质期; - 0.77 - 在肾造影期
	M. Shehata等 人, 2021年 [31]	-	从人工分割的有肿块的肾脏中区分出形态(形状评估)、纹理和功能特征。这些特征通过前向传播网络分为良性和恶性。对于恶性肿瘤, 特征通过前向传播网络来确定透明细胞癌和非透明细胞癌	将肾脏肿块分为良性和恶性: - F1分数: 0.98 肾脏分类: - 准确率: 89.6
在CT图片上的的 尿石确定	A. Caglayan等 人, 2022年 [35]	-	xResNet50	结石小于1cm: - 准确率: 85%; - F1分数: 0.85 结石为1-2cm: - 准确率: 89%; - F1分数: 0.89 结石大于2cm: - 准确率: 93%; - F1分数: 0.93

表1结束

1	2	3	4	5
在CT图片上的 尿石确定	C. Daniel 等 人, 2022年[36]	90个检查	用于肾脏分割的3D U-Net、噪声抑制程序、 感兴趣区域剪切、用于分类的13层3D CNN	- AUC: 0.95; - 特异性: 0.91
	Y. Cui 等 人, 2021年[45]	117个检查	连续使用3D U-Net架构进行肾脏分割。获得 的数据用于五个3D EU-Net架构, 每个架构负 责根据S. T. O. N. E. 标度参数之一进行分类	肾脏和静脉窦的分割: - 戴斯相似性系数: 0.93 结石检测: - 准确率: 90.3%; - AUC: 0.96
	K. Yildirim等 人, 2021年[47]	100个检查	xResNet50	- 准确率: 97% - F1分数: 0.97

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>

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>

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

绪论

基于人工智能的技术在现代科学（尤其是医学）实践中的应用¹给科学研究人员提出了一系列问题：人工智能的认识论地位是什么？在确定此类地位时会遇到哪些伦理挑战？人工智能的认识论地位问题需要澄清，因为将人工智能积极融入科学实践不可避免地会引起这样的担忧：技术的主动性既威胁到作为寻求客观观点决策者的医生本身主动性，也威胁到作为与科学相关的认识论美德²。

L. Daston和P. Galison的“客观性历史概念”项目³，作者以研究具体的物质科学实践（即为自然科学地图集绘制视觉图像的实践）为例，证明了客观性作为一种认识论美德的历史性，该项目主要基于两个方面：认识论美德（尤其是客观性）和视觉性。

“对科学认识形式的关注带来了两个问题。需要怎样的实践才能产生这种图像？需要哪些实践来培养使这种认识成为可能的科学信念？科学认识的历史总是需要这样的双重运动：一方面是图像认识论的展开，另一方面是科学信念伦理的培养。忠实于自然一直是一种三重承诺：视觉的、认识论的和伦理的。当忠实于自然的承诺被打破，自然与人工制品融为一体时，会发生什么呢？是时候看看当代的科学地图集了：在这些图像中，制作的过程同时也是观看的过程”⁴ [1, P. 541]。科学工作对象视觉化的具体实践将这两个方面紧密联系在一起³。

图像和实践性质的变化显示了一种或另一种认识论美德的作用。在这方面，通过使用数字技术和基于人工智能的技术来改变可视化，可以让我们质疑客观性认识论美德和科学信念的转变。各种可视化方法（使用图表、地图、照片、地图集）正在成为现代科学研究论证的基本组成部分之一。得益于新数字技术的性能，可视化不仅仅是一种插图，它本身也是一种研究形式。从表象到呈现的转变标志着一种新的观察方式和科学实践：操纵视觉图像开始与操纵所描绘或观察的对象本身具有相同的含义。计算机建模和新的可视化方法是继观察和实验之后科学实践

的又一次革命性突破。在科学数字化和创新的时代，在技术和科技开始在科学知识的生产中发挥重要作用的背景下，客观性作为一种认识论美德的现状和可能的未来是什么？新的科学实践是什么，新的美德可能是什么？如果实践是历史性的，那么美德是如何变化的？美德的变化是否与实践所依据的目标/目的的变化有关？除了美德之外，科学信念还能用其他东西来定义吗？当基于人工智能的技术得到增强时，科学信念会发生怎样的变化？

现代科学实践：人工制品的物质性和认识论地位

在现代科学实践中，客观与主观、抽象与具体、开放与制造之间的界限变得模糊。人工制品开始在科学知识的形成过程中发挥重要作用，并影响其主要特征，包括客观性，而客观性不再被理解为独立于主体的抽象科学特征。随着技术的发展，技术人工制品⁴变得越来越重要，例如，它们是在科学实验室中制造的，具有创造新知识的基本新特性。除了其功能性目的之外，物质性是人工制品最重要的特性之一：人工制品不是理想的物品，尽管它们可以成为形成理想的工具。此外，人工制品与人类的生活世界、文化环境、历史时代和社会实践有着内在的联系，这实际上使人工制品在很大程度上依赖于（从本体论上，而不是从因果论上）与之互动的实践过程。在创造人工制品时，人类改造和调整自然，形成新的物品。改造和认知世界的实践是通过生产和使用人工制品形成的。考虑到科学实践中使用的技术人工制品的特殊属性和功能，我们可以说，它们本身就是维护科学知识稳定性的一个重要构成要素。因此，“人工制品应被理解为事物系统中的“物质”元素，它们能够代表文化的特定含义、事物的生产机制、学习和掌握含义和隐喻的过程，并允许文化发生变化。正是这些人工制品具有本体论意义，因为它们体现文化的特定含义，没有它们，文化就不可能存在，也不可能得到体现”⁴。

¹ 说到现代科学实践，我们指的是一个从根本上说是复杂的、经验多样的科学空间，其中除了命题式的知识生产方式外，还包括图表、图解、视觉图像等各种非命题形式。A. Mol的研究项目就是一个生动的例子，它展示了科学实践如何与其说是认知其对象，不如说是在实践中创造其对象。该项目以动脉粥样硬化这种疾病在分支实践中的实现为例，专门研究了医学实践本体的多重性^[2]。

² 客观性作为一种认识论美德，是在观察者与观察实践复杂协调的某一历史阶段出现的，并在某些视觉实践和可视化技术中得到体现，因为认识论美德作为稳定的性格特征是在具体的研究实践中培养出来的，并通过这些实践反过来形成某种类型的科学信念。科学信念的每一次实践都是为了实现某种目标。因此，持续的实践使认识论美德的变化成为可能。

³ 《为自然本身代言》成为19世纪下半叶出现的一种新的科学客观性的口号。法国生理学家Étienne-Jules Marey研究了科学中的多种视觉方法，他和他的同时代人担心自然和科学之间受到人为干扰，转而采用机械复制图像的方法来消除可疑的中介。他们利用测谎仪、照片和其他设备，试图绘制地图，即所谓的“可观察科学的圣经”。地图集为有关科学客观性的讨论设定了新的方向^[3]。地图集为视觉科学提供了工作对象，训练眼睛将某些类型的对象识别为典范（可称为“典型”），并以特定的方式观察它们。如果地图集展示的是利用新工具获得的图像（如20世纪初的X射线地图集），那么地图集所属的整个领域也必须以新的方式来解读。由于地图集训练的是眼睛，因此它们必然是视觉性的，即使在其他感官发挥重要作用的学科中也是如此^[3]。

⁴ “技术人工制品是专门为某一特定目的而创造的物品；而自然物品则是在没有具有任何意图的因素的干预下产生的。人工制品在本质上具有意图属性，而自然物则没有”^[5]。一方面，人们普遍认为，人工制品是为特定目的而制造的物品（与自然物品相反）。然而，在专门研究现代认识论的著作中，人们正确地指出，技术人工制品不仅会是人工制造的东西，也会是用来完成某些任务的相当自然的、有生命的有机体。在这种情况下，应该承认，人工制品的构成属性不是其人工性质，而是其在人类认知活动中的用途。人工制品的功能性是其基本属性之一。“疫苗、强子对撞机和掘土棒也是人工制品。所有这些物品都与人类生活世界息息相关，这也是它们能够成为技术人工制品的原因”^[4]。

一个物体的人工性不能仅从其基本特征来解释,也不能脱离其他物体、关系、程序的综合体,即揭示该物体作为人工制品的普通条件。M. Polanyi将工具的存在或工具本身在一定意义上表述为有别于其作为客观“机制”的适宜性的东西。它成为人类身体的一种延伸:我们把工具包装进自己的身体,或者以这样一种方式延伸我们的身体,使我们与这个东西相处融洽。正如M. Lynch所指出的,Polanyi将工具的这种身体延伸称为内部化[6]。“客观”与“制造”之间的对立问题源于人工制品与自然客观性之间的区别,这种区别在实验室科学实践中受到质疑⁵。

Lynch在分析科学实践中的人工制品(伪影)时,将其分为积极人工制品和消极人工制品。第一类人工制品的特征是外部物质表现(如显微镜玻璃上的污渍):在这种情况下,它们属于主观观察条件,即它们被认为取决于感知的工具条件。Lynch指出此类人工制品的几个特征。首先,它们是物质性的,即可见和可读的。其次,它们是无处不在的、可复制的,它们的出现就像日常的困扰,栖息在图像技术准备工作中。此外,一旦将其检测为伪影,就可以毫无问题地将其与适当构建的图像特征(如电子显微照片)区分开来。最后,一旦检测到这些伪影,就需要对其进行读取,这通常会提出一个问题,即在最终分析中是否要考虑到检测到的伪影,以及在进一步的工作中是否要使用这些伪影。

然而,正如Lynch所指出的,实验室人工制品的“人种学”关注存在一些问题。首先,不难看出,作为实例报告的人工制品数量并不能详尽无遗地说明研究中可能被认为是人为的一切。此外,什么被认为是人为人工制品往往取决于报告记录中的表述方式。例如,神经超微结构可表示为一种分析记录,在通过阅读该记录访问的神经实体领域中,该记录被赋予人工制品的地位。人工制品表示格式的特征可能包括照片的二维性质;黑白纹理变化,勾勒出被拍摄现象的形状;以及照片系列的顺序排列,描绘出事件的连续序列[6]。记录可以说是一种不可见现象的可视化形式,而人工制品在许多情况下是在实验室报告中发现的,是以前未曾预料到的现象。人工制品之所以成为发现,是因为它们往往是以前未曾探索过的领域中出现的新现象。按照Lynch的定义,这些就是所谓的情境人工制品,或者说是消极人工制品。Lynch写道,无论如何,这些成为发现的人工制品的例子表明,观察或实验的结果在很大程度上取决于进行观察或实验的条件。

根据上述积极和消极人工制品的具体特征及其在科学实践中的作用,Lynch举例说明了作为人工制品的小胶质细胞现象的发现[6]。它的“不可信”并不是经验上的不可能,而是更可信的替代版本中的一个孤立案例。导致毛细血管中的小胶质细胞受到特别关

注(几张特写镜头照片被整理成一个系列)的理论背景有助于对这一现象进行更详细的研究。小胶质细胞照片之所以存在问题,不仅是因为它与关于小胶质细胞应如何在大脑中产生的实验室假设相矛盾,而且还是因为照片所记录的另一个与之相竞争的假设的存在而加剧了问题的严重性。小胶质细胞不仅通过实验室版本的大脑生理学无法解释的途径以某种方式出现,而且还可以作为另一种可能解释的证据。小胶质细胞在毛细血管中的位置成了一种不知不觉的建构,而不是对真实情况的把握[6]。

这样一个人工制品的例子并不是积极意义上的物质,因为可见性本身是不存在的。问题在于对物质性的不同理解。轴突萌发所展示的物质延伸方向与实验室研究人员认为不容置疑的方向不同,因此它受到了另一种物质论点的质疑[6]。在这种情况下,从有关萌发轴突的特定论战角度来看,人工制品是可以识别的,因此也受到了质疑。在这一案例和类似案例中,人工制品与其说是“东西”,不如说是对立观点冲突中的“反东西”。除了“东西”之外,人工制品还可能是与公认的计算结果相反的可能性。这些可能性常常被认为是观察中不存在的,而不是存在的(照片中的斑点、污点、模糊,可被视为“侵入”⁶)。在这种情况下,人工制品出现在不确定的情况下。

消极人工制品不是指观察领域中的侵入、扭曲或具体缺陷,而是指没有预期的结果或效果。就“消极人工制品”而言,实验或观察程序没有产生积极的结果,意味着实验室工作是可以接受的,考虑到可能出现的意外情况,而这些意外情况反过来又要对所获得的结果负责。由于不确定性造成的失败会引发对为什么没有取得预期结果的调查。Lynch认为,这种负面结果的不确定性是对实现客观性所必需的技术视野的一种补充[6]。未能履行职责会带来不同的伦理附加意义,这些附加意义取决于当地的具体情况:在某些情况下,这些附加意义可能会在或多或少的客观环境中得到体现。

积极人工制品是对自然现象可见空间的侵入,出现在力求避免主观错误可能性的研究工作中。消极人工制品则表明研究工作是在寻找难以捉摸的对象。然而,这还不足以避免错误,因为要取得成功,就必须控制环境,使其产生预期结果。消极人工制品作为“隐藏”事物的可能性而存在。隐藏事物作为一种可能性而存在,就像人工制品本身一样,它隐藏着其可用性,直到技术改造在测试中记录它的存在。因此,消极人工制品为突发事件中事物的现实化创造条件。当出现错误时,这些错误被视为主观因素,阻碍客体本身的展示。工具和仪器也有其不完善之处、缺陷和相关错误。因此,科学实践的物质性(稍后将说明)直接影响到科学客观性的产生,并赋予产生这种客观性的技术以认识论地位。

⁵ 正如K. Popper所指出的,“客观性与科学方法的社会性密切相关,科学和科学的客观性不可能是科学家个人努力做到客观的结果。它只能是科学家群体的结果。科学客观性可以用主体间科学方法来描述。但是,自称为知识社会学家的人几乎完全否定科学的社会性”[6]。

⁶ 例如,G. Galilei的实验方法(不同于F. Bacon的经验方法)使得通过技术活动将推测性的构造和经验性的模型交织在一起成为可能。同时,使用望远镜观测太阳黑子必须作为观测的结果而不是望远镜产生的人工制品来辩护。

现代医学实践：分布式代理与人 工智能的认识论地位

与科学研究中的“物质转向”有关的对经典认识主客体关系模式的否定，导致研究过程及其结果（科学知识）的所有要素都被归结为社会特征。“遗忘人工制品（在事物的意义上）意味着创造另一种人工制品（在幻觉的意义上）：社会，而社会只应由社会来支撑”[7]。所获知识的内容由其构建的社会过程决定。获得的知识是科学家活动的最终结果。然而，如果说在古典科学中，知识因其与研究对象的对应关系而获得了一种逻辑形式，那么现在，知识则因其作为人工制品在社会中成功发挥作用的能力而成为一种科学成果，并排除社会活动对其产生的一切痕迹。科学家的活动（与其说是脱离研究对象，不如说是一种特定形式的主体化，即自身从属于研究对象，同时研究对象抵制从属关系）造成一种科学的无主体性：科学家是始终存在的研究对象的评判者，但不是对研究对象进行评判的终结者。尽管B.Latour说“在科学中不存在“终审判决体”（*res judicata*）”[8]，但用他自己的话说，仍然存在决策的第三方：独立的混合体（他代表科学家发言，而科学家则代表“事物”发言）。科学家的任务与其说是让这一对象从属于自己，不如说是让它“说话”。事实本身并不会说话，但在实验室里，事实扮演着双重角色：一方面，事实代表着关于事实的说法，另一方面，事实决定着关于事实的说法的真伪[8, P.82]⁷。

对Latour来说，科学不仅是一种话语：它首先是一个产生事实的实践网络。在把科学理解为技术科学的背景下（当技术和科技不是科学的附属品，而是科学发展的必要元素时），人工智能被赋予一种特殊的认识论地位，它是一种代理人（或行动者），不能脱离应用它的科学实践。在这方面，数字化时代的科学创新问题与科学信念如何变化的问题密切相关：为了从事科学工作，科学家必须对自己做什么，今天作为

一种认识论美德的客观性发生了什么变化？20世纪末，新技术和新的混合科学方式的出现，使早先表现自然的看似不言自明的方式黯然失色。在科学实践中，将自然与人工制品并置，以原子的维度为工具制作图像，这导致了从表象策略到呈现策略的转变⁸。20世纪至21世纪纳米技术的发展，使Daston和Galison提出“图像即工具”的科学可视化新模式。因此，现代科学图像与其说是对所表现对象的再现，不如说是对其进行操作的工具⁹。从这个意义上说，最能体现表征策略和呈现策略之间差异的深刻变化恰恰发生在科学信念的层面上：“科学家和工程师，至少在这个混合领域中是截然不同的角色，却开始以各种方式失去这种差异。〈……〉当工程科学信念开始稳定下来时，它与对图像的新态度也同时发展起来。它们成为工具，成为硬件的一部分，更像是电脑屏幕，显示远程手术中遥控机器人的操作、太空中卫星的轨迹改变、有毒化学品的混合或炸弹安全处理”[1]。在创建和观察客观图像的过程中，人们倾向于尽量减少信念的作用，甚至拒绝信念¹⁰，因为信念会以任何方式干预或误视和误解所观察到的现象，这种倾向在使用基于人工智能技术的当代科学实践中日益明显。在这种情况下，我们似乎有理由提出这样的问题：新技术是否有可能抹杀作为一种认识论美德的客观性所支配的科学信念？我们是否正在目睹切断伦理学与认识论之间联系的新认识论制度的出现，或者说取代科学信念的算法正在成为认识论美德承载者？

因此，举例来说，被定义为“客观”科学家的科学信念类型是一个严谨认真的观察者形象，他不干预研究过程，只是公正地记录所观察到的现象并对其做出正确的解释。客观（即坚持客观性的认识论美德）不仅意味着从事科学研究，而且首先意味着克制自己的意志和信念，例如不对照片进行修饰。从这个意义上说，认识论美德的改变与其说是科学实践的改变，不如说是规范科学家行为的伦理态度的改变。然而，正如Daston和Galison所指出的，“所有这三种美德都以各自的方式服务于一个共同的目的，即我们称之为

⁷ 法律世界和科学世界如此紧密地联系在一起绝非偶然：它们有一个共同的优点，那就是通过距离和精确度实现公正。每个领域都使用自己的语言和思维方式。例如，Latour提议将国务委员会视为一个实验室，以寻求科学家所追求的客观性。政府参与与科学家的相似之处在于“他以自己的名义发言和发表文章；同样，每一位自诩为启蒙者的科学家身上都有政府参事的影子。因此，政府参事的形象是一个怪异而复杂的混合体：它具有*lex animate*的主权，即体现在个人身上的法律；但在我们面前的情况中，受这一法律约束的只是个人本身。〈……〉政府参事是一个最具体的例子，它旨在产生反对意见，从而产生客观性”[8]。法律活动和科学活动的共同根源是对文本和记录进行一般操作的艺术。

⁸ 这种转变的特点是：“一方面，早期的地图集试图通过表现形式来达到忠实于自然的目的。将自然正确地搬上版面，既可以理解为坚持自然真实的理念（18世纪），也可以理解为坚持机械的客观性（19世纪）或训练有素的判断力（20世纪）。另一方面，还有最新形式的图片库，即演示文稿。演示策略既可能与新型事物（重新组装的纳米管、DNA链或二极管）有关，也可能与演示文稿固有的傲慢倾向有关，即刻意改善图像以解释、说服、取悦，有时甚至推销”[1]。正如O.E.Stolyarova所说，通过区分这两种策略（即表征和呈现），Daston和Galison隐晦地创造了一种“集体成为”的本体论[9]。用J.Hacking的术语来说，“集体成为”[9]的认识论含义不是作为对已有事物的再现的表征，而是作为新事物的生产的干预。在这里，我们涉及的是以实用主义方式诠释的建构主义：“第二性自然”为我们的理论和实践强加一个本体论框架。在现代认识论中，对主体的理解正在发生变化：无肉体的主体正在被有肉体的主体所取代。根据Latour的观点，有肉体的主体与世界互动的产物不再是客观现实的主观图像，而是人工制品，它们扩大我们的可能性以及与其他人和社会群体的联系，从而改变我们的需求。

⁹ 现代科学家操纵纳米物体及其纳米图像的能力本身就很不起了。然而，同样令人惊叹的是，“使用原子力显微镜（测量微小探针与扫描表面之间的力）来制作这些图像，并不是为了表现“自然”现象。相反，这些图像和类似的触觉图像是制造过程本身不可分割的一部分”[1, P.545]。

¹⁰ 然而，值得注意的是，将信念最小化的愿望，除了与将主观性最小化的愿望联系在一起，并因此减少与人为因素相关的错误之外，“还可以使医生免于执行部分常规操作。将人工智能应用于医疗领域的另一个重要优势是可以减少时间和材料成本”[10]。

忠实再现自然”[1, P.540]。到20世纪末,随着新技术的出现,那些看似不言自明的表现自然的方式已黯然失色¹¹,科学信念也在发生转变并得到彻底扩展,考虑到作为决策过程中不可或缺代理人的神经网络和基于人工智能的技术。

由于科学中的视觉表征与计算机和计算格式的组织日益紧密,其数字物质性需要一种特殊的方法¹²。如果说不久前,在20至21世纪之交,科学家-观察者的存在被认为是一种现象,未来应通过改进算法和图像处理能力来消除这种现象,而无需人工干预的话,那么现在,新的(与以前的脑图绘制方法相比)数字地图集的创建则对实现所谓数字客观性的信念控制和限制提出了新要求¹³[12]。数字扫描被放置在一个复杂的基础设施中,它提供的视觉知识与观察者对机械得出的客观表象进行简单评估的方式大相径庭。除了客观视图之外,还需要某种关系视图,通过这种视图,图像被视为与研究对象相关的一组数据。科学实践中积累的大数据虽然努力提供详尽无遗的数据表示,但只能有选择地反映有意义的信息,这在很大程度上取决于所使用的技术和数据收集平台,同样重要的是,取决于对所使用数据的本体论态度。换句话说,数据意味着一种选择性的视角,以某种方式配置,并受限于某些工具的使用[13]。

新的分析方法(基于机器学习、计算机视觉和新可视化方式的数据管理新方法的开发)标志着改变现代科学研究的创新。例如,命题在纳米科学中几乎不存在,因为其重点是创造和研究新现象,因此其重点也是一种特殊的捕捉这些现象的可视化方式来。然而,在这种情况下是否会产生一种新的表征模式,这个问题并没有简单的答案:人们可能会怀疑这种模式有多新。尽管如此,毫无疑问,在纳米技术和其他一些新兴科学领域,与真实研究对象的相似性不再是对研究对象的主要要求。除了扫描和成像技术实现的机械客观性之外,数字地图集“还通过计算机化统计和定量仪器的参与而形成,这些仪器提供进一步的验证和确保客观性的机制”[12]。这两种情况的假设都是,数字图像处理可以通过部署自动化流程来促进客观性的认识论理想,从而减少数据处理中的干预需求。

最后,客观性的认识论美德在历史上作为科学性的理想而形成,但作为一种科学价值,它可以被另一种认识论美德所取代,而另一种认识论美德的形成则是使人工制品越来越接近图像的趋势,图像变得工具化而非视觉化。科学视觉变得与视觉图像的生产密不可分。当代从再现到呈现的转变成为视觉实践和客观性历史上的一个转折点,强调再现实践与其构建过程的并列关系:摄影图像的精确性并不代表技术的客观性,它被理解为将主观性降至最低的愿望¹⁴。

引入基于人工智能和计算机视觉的技术,是为了使图像流标准化,以便对缺陷、病理、筛查方案的规模等进行初级和自动检测。例如,已开发的生物医学图像分析服务旨在科学研究在莫斯科医疗保健系统中使用基于人工智能数据分析结果的决策支持方法的可能性¹⁵。除其他外,该服务旨在最大限度地降低诊断错误的风险,但这并不排除假阳性结果。同时,医生作为“专家”的角色并没有从诊断过程中消失,而是以“人工智能”角色和“人工智能+专家”的混合角色作为补充。医生在做出决定时的客观性很大程度上取决于对服务所提供数据的分析。不过,最初的诊断结果并不需要医生的专家意见:只有在下一阶段,如果人工智能的结果不令人满意,才可能需要:计算机视觉算法将对病人图像进行分析,只有在必要时,这些结果才会由经验丰富的专家进行验证(图1、图2)。

伦理挑战: 人工智能主观性和主体性的优缺点

基于人工智能的机器人设备已经在诊断、治疗和手术方面为医生和患者提供了重要支持。俄罗斯已经有了机器人医疗综合体,例如,AST(Assisted Surgical Technologies)¹⁶。在治疗方面,传统上由作为初级医生的内科医生进行初步诊断。然而,机器人已经开始取代他的工作:安装在病人身体上的特殊传感器可以收集所有信息,并在发现病变时将信息传送给医生。该系统还能代替医生自己进行诊断。

¹¹ 例如,使用数字脑图谱进行的观察和可视化主要是在计算机显示器进行的[11]。这意味着观察者、观察对象、用于此目的的技术以及促成观察实践的制度安排之间的关系发生了变化。与Daston和Galison所考虑的地图集不同,数字地图集具有表征工具而非表征工具的特征,因为它既可以表征,也可以用来增强表征。

¹² 例如,脑部扫描的结果并非快照,Daston和Galison关于机械客观性的一些现实主义假设并不适合扫描后的脑部图像[11]。计算机技术的进步使得脑部扫描被嵌入到数字化和网络化的环境中,使扫描过程成为呈现而非表征的过程。

¹³ 20世纪90年代是“大脑十年”,当时创建了许多数字和电子资源,以理顺和整合不同的神经生物学领域。这种方法被称为“神经信息学”。在改进脑图谱的过程中,根据新技术固有的可能性和涉及多个维度的项目固有的标准化限制,对客观神经生物学知识的构成进行了重新诠释。有人提出了“数字客观性”的概念,作为现代网络科学中理想、方法和认知对象的特定组合的名称[12]。

¹⁴ 例如,R.Buiani描述了一些案例,在这些案例中,该技术无法识别有意义的差异,因此研究人员不得不从字面上绘制图像元素,突出它们并将它们结构化[14]。

¹⁵ 这项研究正在三个项目中实施:《使用创新计算机视觉技术进行医学图像分析并进一步应用于莫斯科市医疗系统的实验》;HUB是医生的人工智能顾问(为医生提供放射检查自动分析服务);“医疗保健中的语音识别技术”是一种基于人工智能算法的自动语音转文字技术,医生可通过语音命令控制工作站,并口述检查描述,而无需手动打字[15]。

¹⁶ https://new.fips.ru/registers-doc-view/fips_servlet?DB=RUPAT&DocNumber=2715400&TypeFile=html[访问日期: 2024年2月9日]。




图1。医生远程医疗平台项目页面截图及研究过程描述。

我们提供的服务:

人工智能服务+专家
莫斯科放射科医生使用的计算机视觉算法可以在15分钟内分析病人的图像。
如有必要，人工智能的结果将由经验丰富的专家进行检查。

专家
代表贵医疗机构签署一份协议，以获得莫斯科放射诊断参考中心的服务：任何方式的检查初步描述、第二意见、审核、鉴定。

成为联邦项目的参与者
成为联邦项目的参与者，将病人经COVID-19确认的CT检查数据上传到全俄放射诊断数据库。
这些图像将成为参考数据集的基础，用于评估医用人工智能的准确性。

详情 **详情** **详情**

图2。医生远程医疗平台项目页面截图及所提供服务的说明。

俄罗斯的综合诊断系统RoboScan可以自动进行超声扫描。

在医疗实践中熟练使用神经网络（例如，用于COVID-19肺部病变的检测）可以减少断层扫描的X射线剂量，因为这种预先训练好的神经网络模型在某些方面已经起到了专家的作用¹⁷。因此，数据收集和初步诊断的工作，以及在某些情况下初步决定的提出，都是标准化和正规化的，这应有助于提高客观性。这一方面减轻了医生作为专家的负担，使他们能够专注于检查和解释数据、描述数据和形成结论。医生将越来越多的职责移交给人工智能，同时也将处理

数据、诊断、制定治疗方案、与病人建立互动，包括决策等职责移交给人工智能。另一方面，这自然也提出了一个问题，即人工智能多快能够完全取代医生，在这条道路上我们已经面临着哪些伦理挑战？

如果出现错误诊断或未能检测出病理，从而导致相应的后果，谁将是决策的责任主体？俄罗斯是世界上最早提出风险和威胁的国家之一（在《人工智能道德守则》[17]中被列为对权力和自由的威胁），这些风险和威胁会是因医学领域基于人工智能技术的数字化和应用而导致的：歧视、隐私权的丧失、对人工智能失去控制、人工智能算法的错误对人造成伤害、将

¹⁷ “所提出的方法允许减少检测COVID-19所需的X射线投影总数，从而在不显著降低预测准确率的情况下减少辐射剂量。对COVID-CTset数据集中的16名患者进行了评估，结果表明，所提出的方案平均减少了15.1%的剂量，而预测准确率平均仅降低了1.9%，与固定方案相比，帕累托最优得到了改善” [16]。

人工智能用于不可接受的目的。例如，俄罗斯联邦卫生监督局最近暂停使用基于Botkin.AI的CT图像分析系统，“原因是该系统可能对公民的生命和健康造成危害”¹⁸。

目前，决策不再是人类专家的特权：这一职能正在转移给智能系统。如果不把决策权转移给技术系统，就不可能创造出一个类似自然的技术圈，因此，在未来10–20年内，这一趋势只会继续¹⁹。现代医学的数字化转型也发生在交流层面，“医生和病人之间可能因技术障碍而彼此疏远。另一方面，数字技术带来了网络空间扩大的现象，医患之间的融合和跨越现有界限（尤其是地理界限）的可能性正在急剧增加。这也为专家医生从其传统的专业领域中取而代之创造了可能，但同时也为形成网络集体专家主体（数字实验室和医生联合会）提供了机会”^[19]。

“在数字技术的帮助下，医生的专家职能被准专家职能所替代和部分取代的趋势也证明了一种新的交流形式，即从专家（医学专业人员）和非专业人员（非专业病人）之间的关系转变为“医生+软件——病人”的混合模式，并在遥远的未来转变为“软件——病人”的交流模式，专家（医生）失去了作为绝对（或接近绝对）知识载体的地位，而将这一权利赋予了数字软件。

后一种模式是以技术为中心的，但在某种意义上，它也是以病人为中心的，使医生的角色更加平等”^[19, P.166–116]。将专家职能下放给技术表明了将医生从诊断错误中解放出来的普遍趋势。人工智能对病理或疾病发展风险的判断越准确，用算法取代专家功能的愿望就越强烈，决策支持系统不仅自以为人类设定目标工具的角色，而且自以为执行复杂操作的正式演员的角色的过程就越强烈。这“导致人类视线的无关性和冗余性，以及错误、扭曲的评估和不可救药的偏袒。技术被赋予对其所面对的现实图景做出判断的功能”^[19, P.167–168]。那么可以想象，如果限制信念而倾向于将信念最终转移到人工智能上的趋势继续下去，那么在不久的将来，我们将不可避免地不得不停止将基于人工智能的技术视为工具，而考虑到其全面的主体性和主观性，以及其所有的利弊。

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.

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 AY, 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, Vakhshaint 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/>

¹⁸ <https://www.kommersant.ru/doc/6350252> [访问日期: 2024年2月9日]。

¹⁹ 目前还没有关于医生和病人对在医疗实践中实施人工智能的态度进行调查的大型研究。不过，最近首次在医生中开展了一项民意调查，以评估他们对在医疗和保健中使用人工智能的兴趣，并确定实施人工智能的问题和前景，调查得出了相当乐观的结论：“俄罗斯医生赞成在医疗中使用人工智能。大多数受访者认为，人工智能将来不会取代他们，而会成为一种有用的工具。首先，它将优化组织流程、研究和疾病诊断”。同时，也注意到，“在使用人工智能可能出现的问题中，有64%和60%的受访者指出，人工智能缺乏灵活性，在有争议的问题上应用有限。56%的受访者认为，如果用于分析的信息不充分，使用人工智能做出决策就会受到阻碍。三分之一的医生担心经验不足的专家参与人工智能的开发，89%的受访者认为医生应参与医学和医疗保健领域人工智能的开发。只有20位参与者（6.6%）回答说，他们同意人工智能可以取代他们的工作。同时，76%的受访者认为，在未来，使用人工智能的医生将取代不使用人工智能的医生”^[18]。

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).

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

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.

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

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