

Анализ подходов к глубокому обучению для автоматизированного выделения и сегментации предстательной железы: обзор литературы

А.Э. Талышинский¹, Б.Г. Гулиев^{2,3}, И.Г. Камышанская^{1,3,4}, А.И. Новиков^{2,5}, У. Жанбырбекулы⁶, А.Э. Мамедов⁷, И.А. Поваго², А.А. Андриянов²

¹ООО «Мед-Рей»; Россия, 129343 Москва, пр-д Серебрякова, 11, корп. 1;

²ФГБОУ ВО «Северо-Западный государственный медицинский университет им. И.И. Мечникова» Минздрава России; Россия, 191015 Санкт-Петербург, ул. Кирочная, 41;

³СПб ГБУЗ «Городская Мариинская больница»; Россия, 191014 Санкт-Петербург, Литейный пр-кт, 56;

⁴ФГБОУ ВО «Санкт-Петербургский государственный университет»; Россия, 199034 Санкт-Петербург, Университетская набережная, 7–9;

⁵ГБУЗ «Санкт-Петербургский клинический научно-практический центр специализированных видов медицинской помощи (онкологический) им. Н.П. Напалкова»; Россия, 197758 Санкт-Петербург, пос. Песочный, Ленинградская ул., 68А, лит. А;

⁶кафедра урологии и андрологии НАО «Медицинский университет Астана»; Республика Казахстан, 010000 Астана, ул. Бейбитшилик, 49А;

⁷ФГАОУ ВО «Самарский национальный исследовательский университет им. акад. С.П. Королева»; Россия, 443086 Самара, Московское шоссе, 34

Контакты: Али Эльманович Талышинский ali-ma@mail.ru

Введение. Определение границ предстательной железы является начальным шагом в понимании состояния органа и в основном выполняется вручную, что занимает длительное время и напрямую зависит от опыта рентгенолога. Автоматизация в выделении предстательной железы может быть осуществлена различными подходами, в том числе с помощью искусственного интеллекта и его субдисциплин – машинного и глубокого обучения.

Цель работы – детальный анализ литературы для определения наиболее эффективных способов автоматизированной сегментации предстательной железы по снимкам мультипараметрической магнитно-резонансной томографии посредством глубокого обучения.

Материалы и методы. Поиск публикаций проводился в июле 2022 г. в поисковой системе PubMed с помощью клинического запроса ((AI) OR (machine learning)) OR (deep learning) AND (prostate) AND (MRI). Критериями включения были доступность полного текста статьи, дата публикации не более 5 лет на момент поиска, наличие количественной оценки точности реконструкции предстательной железы с помощью коэффициента Серенсена–Дайса (Dice similarity coefficient, DSC).

Результаты. В результате поиска найдена 521 статья, из которой в анализ были включены только 24 работы, содержащие описание 33 различных способов глубокого обучения для сегментации предстательной железы. Медиана количества исследований, включенных для обучения искусственного интеллекта, составила 100 с диапазоном от 25 до 365. Оптимальным значением DSC, при котором автоматизированная сегментация лишь незначительно уступает ручной послойному выделению предстательной железы, составляет 0,9. Так, DSC выше порогового достигнут в описании 21 алгоритма.

Заключение. Несмотря на значимые достижения в автоматизированной сегментации предстательной железы с помощью алгоритмов глубокого обучения, до сих пор существует ряд проблем и ограничений, требующих решения для внедрения искусственного интеллекта в клиническую практику.

Ключевые слова: рак предстательной железы, мультипараметрическая магнитно-резонансная томография, искусственный интеллект, сегментация предстательной железы

Для цитирования: Талышинский А.Э., Гулиев Б.Г., Камышанская И.Г. и др. Анализ подходов к глубокому обучению для автоматизированного выделения и сегментации предстательной железы: обзор литературы. Онкоурология 2023;19(2):101–10. DOI: 10.17650/1726-9776-2023-19-2-101-110

Analysis of deep learning approaches for automated prostate segmentation: literature review

A.E. Talyshinskii¹, B.G. Guliev^{2,3}, I.G. Kamyshanskaya^{1,3,4}, A.I. Novikov^{2,5}, U. Zhanbyrbekuly⁶, A.E. Mamedov⁷, I.A. Povago², A.A. Andriyanov²

¹Med-Ray; Build. 1, 11 Serebryakova Proezd, Moscow 129343, Russia;

²I.I. Mechnikov North-West State Medical University, Ministry of Health of Russia; 41 Kirochnaya St., Saint Petersburg 191015, Russia;

³Mariinsky Hospital; 56 Liteynny Prospekt, Saint Petersburg 191014, Russia;

⁴Saint Petersburg State University; 7–9 Universitetskaya Naberezhnaya, Saint Petersburg 199034, Russia;

⁵N.P. Napalkov Saint Petersburg Clinical Scientific and Practical Center for Specialized Types of Medical Care (Oncological); lit. A, 68A Leningradskaya St., Pesochnyy, Saint Petersburg 197758, Russia;

⁶Department of Urology and Andrology, Astana Medical University; 49A Beybitshilik St., Astana 010000, Republic of Kazakhstan;

⁷Samara University; 34 Moskovskoye Shosse, Samara 443086, Russia

Contacts: Ali El'manovich Talyshinskii ali-ma@mail.ru

Background. Delineation of the prostate boundaries represents the initial step in understanding the state of the whole organ and is mainly manually performed, which takes a long time and directly depends on the experience of the radiologists. Automated prostate selection can be carried out by various approaches, including using artificial intelligence and its subdisciplines – machine and deep learning.

Aim. To reveal the most accurate deep learning-based methods for prostate segmentation on multiparametric magnetic resonance images.

Materials and methods. The search was conducted in July 2022 in the PubMed database with a special clinical query ((AI) OR (machine learning)) OR (deep learning)) AND (prostate) AND (MRI). The inclusion criteria were availability of the full article, publication date no more than five years prior to the time of the search, availability of a quantitative assessment of the reconstruction accuracy by the Dice similarity coefficient (DSC) calculation.

Results. The search returned 521 articles, but only 24 papers including descriptions of 33 different deep learning networks for prostate segmentation were selected for the final review. The median number of cases included for artificial intelligence training was 100 with a range from 25 to 365. The optimal DSC value threshold (0.9), in which automated segmentation is only slightly inferior to manual delineation, was achieved in 21 studies.

Conclusion. Despite significant achievements in the development of deep learning-based prostate segmentation algorithms, there are still problems and limitations that should be resolved before artificial intelligence can be implemented in clinical practice.

Keywords: prostate cancer, multiparametric magnetic resonance imaging, artificial intelligence, prostate segmentation

For citation: Talyshinskii A.E., Guliev B.G., Kamyshanskaya I.G. et al. Analysis of deep learning approaches for automated prostate segmentation: literature review. *Onkourologiya = Cancer Urology* 2023;19(2):101–10. (In Russ.). DOI: 10.17650/1726-9776-2023-19-2-101-110

Введение

Мультипараметрическая магнитно-резонансная томография (мпМРТ) является наиболее информативным методом неинвазивной визуализации, который сочетает соответствующие последовательности для анатомо-функциональной оценки предстательной железы (ПЖ). Помимо определения характера ее заболевания мпМРТ позволяет создавать трехмерную (3D) реконструкцию всей ПЖ и ее зон [1], проводить стадирование и динамическое наблюдение за раком ПЖ (РПЖ), а также определять степень его злокачественности.

Различия в протоколах исследования в разных учреждениях приводят к неоднородности качества изображений и затрудняют их сравнение и группирование. Кроме этого, несмотря на унификацию описания ПЖ посредством классификации PI-RADS v2 и v2.1, кривая обучения чтению снимков мпМРТ является достаточно длительной, что опосредует различия в заключениях у разных спе-

циалистов [2]. Помимо этого, ручная послойная сегментация занимает длительное время и напрямую зависит от опыта рентгенолога. Автоматизация в выделении ПЖ может быть осуществлена различными подходами, в том числе с помощью искусственного интеллекта (ИИ) и его субдисциплин – машинного и глубокого обучения. Именно ИИ в последнее время уделяется пристальное внимание по всему миру, однако работы по описанию основных достижений применения глубокого обучения в отечественной литературе либо ограничены обзором средств автоматического анализа и распознавания гистологических изображений [3], либо носят сугубо повествовательный характер с акцентом на основные принципы реализации ИИ в онкоурологии в целом [4].

Цель работы – детальный анализ имеющейся литературы для определения наиболее эффективных способов автоматизации сегментации ПЖ посредством глубокого обучения.

Материалы и методы

Поиск публикаций для включения в данный обзор проводили в июле 2022 г. в поисковой системе PubMed с помощью клинического запроса (((AI) OR (machine learning)) OR (deep learning)) AND (prostate) AND (MRI). Критериями включения были доступность полного текста статьи, дата публикации не более 5 лет на момент поиска, наличие количественной оценки точности реконструкции ПЖ с помощью коэффициента Серенсена–Дайса (Dice similarity coefficient, DSC), а также значение последнего $>0,85$. Дополнительно анализировали список литературы в отобранных для ознакомления статьях. При использовании в нескольких работах одинакового алгоритма с обучением по снимкам одного и того же режима мпМРТ в итоговый обзор включали более современную по дате публикацию. В работах, посвященных сопоставлению различных сетей, в таблицу вносили характеристику наиболее точной с описанием сравнения в текст обзора.

Описательную статистику реализовывали с помощью программного обеспечения SPSS Statistics 26.0. Определение распределения непрерывных данных осуществляли с использованием теста Колмогорова–Смирнова, после чего рассчитывали среднее значение со стандартным отклонением или медиану с минимальным и максимальным значениями в зависимости от нормализованности.

Результаты

В результате поиска найдена 521 статья, из которых были включены только 24 работы, содержавшие описание 33 различных способов глубокого обучения для сегментации ПЖ. Алгоритмы глубокого обучения для автономной сегментации ПЖ, соответствующие критериям включения, перечислены в таблице. Видно, что оптимальным режимом для реализации такого рода задачи является T2, наиболее достоверно отображающий зональную анатомию ПЖ. Медиана количества исследований, включенных для обучения ИИ, составила 100 с диапазоном от 25 до 365. Оптимальным значением DSC, при котором автоматизированная сегментация лишь незначительно уступает ручному послойному выделению ПЖ, составляет 0,9. Так, DSC выше порогового достигнуто в 21 работе.

G. L. da Silva и соавт. описали комбинацию из глубокой сверточной нейронной сети, технологии генерирования суперпикселей с помощью простой линейной итеративной кластеризации, вероятностного атласа, моделирования активного контура и алгоритма оптимизации. Несмотря на сочетание глубокой сверточной нейронной сети на основе суперпикселей с вероятностным атласом, результирующее изображение может иметь неправильную границу. В связи с этим для точной сегментации поверхности ПЖ авторы предлагают использование активного контура в сочетании

с кубическим сплайном Безье. Такой подход обеспечивает значение DSC 0,85 [5].

B. Wang и соавт. описали применение 3D-полной сверточной сети с групповой расширенной сверткой и сравнили ее точность с таковым показателем U-Net и VNet. Представленная сеть состоит из 3 основных частей: этапов сжатия, соединения и расширения. На этапе сжатия (кодирующей части для анализа всего объема) представление 3D-анатомических объектов извлекается с помощью последовательных 3D-сверток, за которыми следует параметрический выпрямленный линейный блок (PReLU). Вместо операции максимального объединения для понижающей дискретизации используется ступенчатая свертка для получения входных объемов для следующего уровня свертки, где объем объектов уменьшается, а их количество увеличивается. Алгоритм соединения имеет структуру, аналогичную описанную выше модулям кодера, но без пошаговой свертки. На этапе расширения используются операции деконволюции (повышающей дискретизации) для получения входных объемов для следующего уровня. Согласно результатам DCS для данного подхода составил 0,86 и значимо превосходил в точности реконструкции U-Net (0,836; $p = 0,023$) и VNet (0,838; $p = 0,018$) [6].

Q. Liu и соавт. описали применение сверточной сети с плотным пространственным объединением (DDSP ConNet) в структуре кодер-декодер, при этом достигалось значение DSC 0,8578 [7].

Y. H. Nai и соавт. оценили эффективность мультимодальных сетей в сегментации ПЖ, а также сравнили их точности путем апробации мономодальной DenseVNet, мультимодальной ScaleNet и моно- и мультимодальной HighRes3DNet. DSC в реконструкции всей ПЖ для упомянутых сетей составил 0,875; 0,848; 0,858 и 0,890 соответственно. Мультимодальные HighRes3DNet и ScaleNet обладали более высоким DSC со статистически достоверным различием только при зональной реконструкции периферической зоны и центральной части ПЖ по сравнению с мономодальной DenseVNet, что указывает на увеличение точности регионарной сегментации при использовании мультимодальных сетей, однако в аспекте выделения всей ПЖ разница была статистически незначима [8].

L. Yu и соавт. описали применение объемной сверточной нейронной сети (ConvNet или MRC-net) с включением как длинных, так и коротких остаточных связей для нивелирования негативного эффекта вариабельности строения ПЖ на точность автоматизированной ее сегментации. Согласно результатам такой подход обеспечивает DSC 0,8693 [9].

A. Comelli и соавт. сравнили точность реконструкции ПЖ при использовании таких сетей, как U-Net, ENet и ERFNet. Согласно полученным данным, именно первые две сети обеспечивают DSC более 0,9, при

Алгоритмы глубокого обучения для трехмерной реконструкции и сегментации предстательной железы
Deep learning algorithms for the three-dimensional prostate reconstruction and segmentation

Авторы, год, источник Authors, year, source	Название сети Network name	Режимы маг- нитно-резонанс- ной томографии Magnetic resonance imaging mode	Количество исследо- ваний Number of studies	Использо- вание открытых дадасетов Use of open datasets	DSC
G.L. da Silva и соавт., 2020 [5] G.L. da Silva et al., 2020 [5]	Глубокая сверточная нейронная сеть Deep convolutional neural network	T2	80	+	0,85
B. Wang и соавт., 2019 [6] B. Wang et al., 2019 [6]	3D-сверточная нейронная сеть с групповой расширенной сверткой 3D-convolutional neural network with grouped dilated convolution	T2/T2	90	+	0,855
Q. Liu и соавт., 2018 [7] Q. Liu et al., 2018 [7]	ConNet	T2	80	+	0,8578
Y.H. Nai и соавт., 2020 [8] Y.H. Nai et al., 2020 [8]	ScaleNet	T2, ДВИ, ИКД T2, DWI, ADC	160	+	0,850
Y.H. Nai и соавт., 2020 [8] Y.H. Nai et al., 2020 [8]	HighRes3DNet	T2, ДВИ, ИКД T2, DWI, ADC	160	+	0,858
Y.H. Nai и соавт., 2020 [8] Y.H. Nai et al., 2020 [8]	DenseVNet	T2, ДВИ, ИКД T2, DWI, ADC	160	+	0,875
Y.H. Nai и соавт., 2020 [8] Y.H. Nai et al., 2020 [8]	HighRes3DNet	T2, ДВИ, ИКД T2, DWI, ADC	160	+	0,890
L. Yu и соавт., 2017 [9] L. Yu et al., 2017 [9]	ConvNet	T2	80	+	0,8693
A. Comelli и соавт., 2021 [10] A. Comelli et al., 2021 [10]	ERFNet	T2	85	+	0,8718
D. Karimi и соавт., 2018 [11] D. Karimi et al., 2018 [11]	Сверточная нейронная сеть со статистическим анализом форм Convolutional neural network with statistical shape analysis	T2	75	+	0,88
A. Ushinsky и соавт., 2021 [12] A. Ushinsky et al., 2021 [12]	Гибридная U-Net Hybrid U-Net	T2	299	–	0,898
K. Yan и соавт., 2019 [13] K. Yan et al., 2019 [13]	Глубокая нейронная сеть с алгоритмом обратного распространения ошибки Deep neural network with backward propagation of errors algorithm	T2	80	+	0,899
H. Jia и соавт., 2020 [14] H. Jia et al., 2020 [14]	3D APA-Net	T2	140	+	0,901
A. Comelli и соавт., 2021 [10] A. Comelli et al., 2021 [10]	ENet	T2	85	+	0,9089
M. Bardis и соавт., 2021 [15] M. Bardis et al., 2021 [15]	Гибридная 3D/2D U-Net Hybrid 3D/2D U-Net	T2	242	+	0,940
Y. Liu и соавт., 2021 [16] Y. Liu et al., 2021 [16]	2D DS-Net	T2	100	+	0,91
Y. Liu и соавт., 2021 [16] Y. Liu et al., 2021 [16]	DeepLab v3	T2	100	+	0,92

Окончание таблицы
End of table

Авторы, год, источник Authors, year, source	Название сети Network name	Режимы маг- нитно-резонанс- ной томографии Magnetic resonance imaging mode	Количество исследо- ваний Number of studies	Использо- вание открытых дадасетов Use of open datasets	DSC
Y. Liu и соавт., 2021 [16] Y. Liu et al., 2021 [16]	Глубокая нейронная сеть с механизмом внимания Deep neural network with attention mechanism	T2	100	+	0,93
D. Nie и соавт., 2019 [17] D. Nie et al., 2019 [17]	STRAINet	T2	50	+	0,914
T.H. Sanford и соавт., 2020 [18] T.H. Sanford et al., 2020 [18]	2D-3D-гибридная сверточная нейронная сеть с трансферным обучением 2D-3D-hybrid convolutional neural network with transfer learning	T2	648	+	0,915
Q. Liu и соавт., 2020 [19] Q. Liu et al., 2020 [19]	MS-Net	T2	79	+	0,9166
W. Wang и соавт., 2021 [20] W. Wang et al., 2021 [20]	SegDGAN	T2	335	+	0,9166
N. Aldoj и соавт., 2020 [21] N. Aldoj et al., 2020 [21]	Dense U-net	T2	188	+	0,921
M.N. Nhat To и соавт., 2018 [22] M.N. Nhat To et al., 2018 [22]	3D MRC-net	T2, ДВИ T2, DWI	280	+	0,9237
M.N. Nhat To и соавт., 2018 [22] M.N. Nhat To et al., 2018 [22]	2D DS-Net	T2, ДВИ T2, DWI	280	+	0,9247
M.N. Nhat To и соавт., 2018 [22] M.N. Nhat To et al., 2018 [22]	3D U-Net	T2, ДВИ T2, DWI	280	+	0,9380
M.N. Nhat To и соавт., 2018 [22] M.N. Nhat To et al., 2018 [22]	3D DM-net-8feat	T2, ДВИ T2, DWI	280	+	0,9511
Q. Zhu и соавт., 2020 [23] Q. Zhu et al., 2020 [23]	BOWDA-Net	T2	80	+	0,9254
Y. Zhu и соавт., 2019 [24] Y. Zhu et al., 2019 [24]	Двойная 2D U-Net Double 2D U-Net	T2	163	+	0,927
A. Meyer и соавт., 2021 [25] A. Meyer et al., 2021 [25]	Анизотропная 3D мультика- нальная сверточная нейронная сеть Anisotropic multichannel convolutional neural network	T2	156	+	0,933
L. Geng и соавт., 2019 [26] L. Geng et al., 2019 [26]	Глубокая нейронная сеть с DDSPP Deep neural network with DDSPP	T2	130	+	0,954
J. Chen и соавт., 2021 [27] J. Chen et al., 2021 [27]	AlexNet	T2	25	+	0,9768
L. Yan и соавт., 2021 [28] L. Yan et al., 2021 [28]	PSPNet	T2	270	+	0,9865

Примечание. DSC – коэффициент Серенсена–Дайса; ДВИ – диффузионно-взвешенные изображения; ИКД – измеряемый коэффициент диффузии.

Note. DSC – Dice similarity coefficient; DWI – diffusion-weighted imaging; ADC – apparent diffusion coefficient.

этом наилучший показатель достигается при использовании ENet (0,9089) [10].

D. Karimi и соавт. описали архитектуру сверточной нейронной сети и стратегию обучения, которая направлена на использование ограниченной изменчивости формы ПЖ и одновременно на решение проблемы нехватки данных для обучения. Ключом к достижению обеих этих целей является статистическая модель формы. Вывод нейронной сети ограничен теми параметрами, которые допускает модель формы. Поэтому задача заключается в оценке значений параметров модели формы, которые наилучшим образом описывают сегментацию ПЖ. Кроме этого, использовался метод дополнения данных, который также основан на модели формы. В этом методе обучающие изображения и их сегментация деформируются с помощью смещений, вычисленных на основе модели формы [11].

A. Ushinsky и соавт. описали использование 3D/2D-гибридной нейронной сети U-Net, достигающей значения DSC 0,898. Гибридная 3D/2D U-сеть была создана путем модификации части U-сети с понижающей дискретизацией для выполнения операций обработки изображений свертки, активации ReLU и нормализации в 3D. Затем эти 3D-изображения были отображены с помощью операции проецирования для соответствия 2D-изображениям на этапе апсемплинга U-Net [12].

K. Yan и соавт. описали применение нейронной сети с алгоритмом обратного распространения ошибки, состоящего из 3 компонентов: слоев свертки и объединения (CP-слои), слоя распространения (P-слой) и слоя потерь F-меры (L-слой), и сравнили данный подход с FCN-16s и FCN-32s, DS-Net и VolConv. Значение DSC для описанного и сравниваемых сетей составило 0,9055; 0,8658; 0,6983; 0,6693 и 0,904 соответственно [13].

H. Jia и соавт. для сегментации ПЖ применили составительную пирамидальную анизотропную сверточную сеть (3D APA-Net). Эта модель состоит из генератора (3D PA-Net), который выполняет сегментацию изображения, и дискриминатора (шестислойной сверточной нейронной сети), который различает результат сегментации и соответствующую ему базовую истинность. 3D PA-Net имеет архитектуру encoder-decoder, которая состоит из 3D-кодера ResNet, анизотропного сверточного декодера и многоуровневых пирамидальных сверточных соединений. Результирующее значение DSC для выделения всей ПЖ сравнивалось с VNet, 3D GCN и 3D U-Net и составило 0,901 против 0,796; 0,817 и 0,818 соответственно [14].

M. Vardis и соавт. описали последовательное использование 3 сверточных нейронных сетей, каждая из которых была реализована с использованием индивидуальной гибридной 3D/2D-архитектуры U-Net. Сети были названы U-NetA, U-NetB и U-NetC. U-NetA отвечала за локализацию ПЖ, создавая вокруг

нее ограничивающую рамку. U-NetB – за конечную локализацию и цельную сегментацию ПЖ, в то время как зональная сегментация реализовывалась с помощью U-NetC. DSC для всей ПЖ, переходной и периферической зон составил 0,940; 0,910 и 0,774 соответственно [15].

Y. Liu и соавт. описали применение глубокой нейронной сети с механизмом внимания (DANN) и сравнили с DeepLab v3+ и U-Net. DSC составил 0,93; 0,92 и 0,91 соответственно, при этом разница между разработанным алгоритмом и аналогами была значимой ($p < 0,05$) [16].

D. Nie и соавт. описали апробацию полной сверточной сети, дополненной использованием стохастической остаточной единицы в сверточных слоях, расширенной сверткой на картах объектов с наименьшим разрешением, пространственно изменяющегося сверточного слоя для адаптации сверточных фильтров к различным областям интереса, а также составительной сети для дальнейшей коррекции сегментированной структуры органов. Данный подход носит название Spatially varying sTochastic Residual Adversarial Network (STRAINet). Сравнение точности сегментации ПЖ проводилось с такими методами, как MALF, SSAE, U-Net, DeepLab v2, RefineNet и PSPNet, использование которых обеспечивало значение DSC 0,793; 0,871; 0,822; 0,805; 0,821 и 0,883 соответственно [17].

T.H. Sanford и соавт. акцентировали внимание на проблему неоднородности магнитно-резонансных (МР) изображений, взятых из разных источников, и описали применение 2D-3D-анизотропной гибридной сети и глубокой многоуровневой трансформации в качестве способа аугментации данных. Этот подход обеспечивает точность сегментации всей ПЖ и переходной зоны со значениями DSC 0,915 и 0,897 соответственно [18].

Q. Liu и соавт. описали использование нейронной сети с применением пакетной нормализации и функции потерь для нивелирования разницы между МР-изображениями ПЖ, полученными при применении разных МР-томографов, и определения оптимального значения градиента для обучения нейронной сети соответственно. Таким образом, авторам удалось достичь значения DSC 0,9169 в определении границ ПЖ при использовании снимков из 3 различных источников [19].

W. Wang и соавт. описали автоматизированную сегментацию всей ПЖ путем использования условных порождающих составительных сетей (SegDGAN). Генератор G представляет собой сеть сегментации, в которой выполняется сквозное обучение. G использует структуру кодер-декодер U-сети. Дискриминатор D представляет собой многомерную сеть выделения признаков с 6 слоями. Каждый слой содержит слой свертки, слой BN и слой с функцией активации ReLU. Наибольшее значение DSC составило 0,9166, что было значимо выше при сравнении точности сегментации при использовании U-Net, FCN и SegAN [20].

N. Aldoj и соавт. разработали алгоритм Dense U-net, за основу которого были взяты ранее апробированные сети DenseNet и U-net. По сравнению с U-net нейронная сеть Dense U-net достигла среднего балла DSC в выделении всей ПЖ 0,921 против 0,907, для центральной части (центральная и переходная зоны) – 0,895 против 0,891 и для периферической зоны – 0,781 против 0,75 [21].

M.N. Nhat To и соавт. описали применение 3D-глубокой плотной сверточной нейронной сети и сравнили ее точность в сегментации ПЖ с 3D U-Net, 2D DS-Net и 3D MRC-net. Значение DSC составило 0,9511; 0,9380; 0,9247 и 0,9237 соответственно [22].

Q. Zhu и соавт. описали адаптивную нейронную сеть с взвешенной по границам областью (BOWDA-Net) со значением DSC в автоматизированной сегментации ПЖ 0,9254 [23].

Y. Zhu и соавт. описали каскадную работу двух U-Net: первая определяла контур всей ПЖ, вторая отвечала за сегментацию периферической зоны. Значение DSC составило 0,927 и 0,793 соответственно, что было статистически значимо выше показателей при применении одной сети U-Net [24].

A. Meuer и соавт. использовали для сегментации всей ПЖ анизотропную 3D-многопоточную сверточную нейронную сеть, представляющую собой архитектуру, подобную 3D U-Net, в соответствии с дизайном кодера-декодера с 4 уровнями разрешения. Примечательно то, что построение осуществлялось посредством использования T2-снимков во всех плоскостях, в отличие от ранее перечисленных способов построения ПЖ по аксиальным срезам. Статистически значимое увеличение DSC в сравнении с одноплоскостной реконструкцией наблюдалось на всех уровнях ПЖ, особенно у основания (0,906 против 0,898) и на уровне верхушки железы (0,901 против 0,888). При этом суммарный уровень DSC для всей ПЖ достигал 0,933 [25].

L. Geng и соавт. описали сеть, состоящую из структуры кодер-декодер с плотным пространственным пирамидальным объединением (DDSPP) для сегментации ПЖ на основе глубокого обучения со значением DSC 0,954 [26].

J. Chen и соавт. описали сеть AlexNet, использующую алгоритмы пакетной нормализации и глобального максимального объединения, достигая значения DSC 0,921 [27].

L. Yan и соавт. описали использование сети синтаксического анализа пирамидальной сцены (PSPNet) и сравнили ее точность с FCN и U-Net. Согласно результатам DSC для PSPNet, FCN и U-Net составил 0,985; 0,8924 и 0,9107 соответственно [28].

Обсуждение

Лучевая диагностика РПЖ нередко носит субъективный характер и не соответствует истинной картине заболевания, что может отрицательно отразиться

на выборе метода лечения и исходе опухолевого процесса [29]. Несмотря на несомненные достижения в диагностике, остается нерешенной задача разработки полностью автоматизированной системы поддержки и второго мнения для верификации точного диагноза без применения инвазивных процедур. Неоднозначность МР-картины, смежные признаки между доброкачественными и злокачественными процессами в ПЖ опосредуют тенденцию к гипердиагностике, вторично приводя к гиперлечению и снижению качества жизни пациентов этой когорты, для которых протокол активного наблюдения мог быть более чем безопасным. Текущая полезность мпМРТ в скрининге обусловлена высокой отрицательной прогностической ценностью РПЖ. Однако в текущий момент реализован не весь ее потенциал.

Конкретизируя проблему интерпретации МР-снимков ПЖ, следует отметить, что определение ее границ является начальным шагом в понимании состояния органа. Например, размер ПЖ сам по себе является ценным маркером для прогноза РПЖ (рак легче определяется при объеме органа менее 50 см³). Объем ПЖ также применяется для расчета плотности простатического специфического антигена – показателя, который помогает дифференцировать доброкачественную гиперплазию предстательной железы и РПЖ, а также может быть использован для прогнозирования исходов радикальной простатэктомии.

В современной практике сегментация ПЖ на МР-снимках выполняется вручную путем послышной разметки ее края, что требует наличия соответствующего опыта и концентрации специалиста. ПЖ не имеет четко очерченных границ в связи с низким градиентом МР-сигнала относительно смежных структур малого таза, и ее детализация напрямую зависит от разрешения изображения.

Для автоматизированной сегментации ПЖ было предложено множество методов и алгоритмов, включая сегментацию на основе деформируемых моделей [30], модели максимального пространственного потока [31] и алгоритмов машинного обучения, таких как «случайный лес» [32], нечеткая кластеризация с-средних [33], распознавание образов [34] и байесовская классификация [35].

Искусственный интеллект – это способность любого инструмента принимать входные данные из предварительных знаний, опыта, целей и наблюдений, а затем создавать выходные данные. Это определение охватывает широкий спектр, начиная от простого термостата и заканчивая самоуправляемым автомобилем. В то время как ИИ обычно предполагает фиксированный, основанный на правилах вычислительный метод, машинное обучение динамически совершенствует вычислительные методы по мере ввода и обучения. В традиционном программировании компьютер получает данные и программу в качестве входных данных,

а затем выдает выходные данные взаимно однозначным образом. Эффективность сильно зависит от качества и размера данных, которые алгоритм получает в качестве материала для обучения.

Принципы глубокого обучения, которое является субдисциплиной машинного обучения и ИИ в целом, являются доминирующими и наиболее перспективными для автоматической сегментации отдельных анатомических структур, в том числе цельной ПЖ и ее зон. В отличие от традиционных методов машинного обучения при глубоком обучении происходит автоматический отбор своих собственных карт объектов во время обучения. Популяризация данного направления связана в том числе с наличием доступных датасетов с МР-изображениями ПЖ. Из включенных в настоящий обзор работ в 23 для обучения частично или полностью используются данные из открытых баз, что устраняет необходимость в кропотливом сборе МР-данных непосредственно в госпиталях.

Несмотря на очевидные преимущества глубокого обучения и высокие показатели DSC, следует акцентировать

внимание и на ассоциированных ограничениях. Во-первых, во многих работах используются МР-данные, полученные при применении различных томографов, что обуславливает явную гетерогенность между снимками и препятствует их использованию для обучения системы сегментировать орган без реализации мер унификации [36, 37]. Во-вторых, в большинстве работ главной целью является выделение всей ПЖ без дальнейшей сегментации ее отдельных зон, что необходимо для аргументированного клинического применения нейронных сетей. В-третьих, существуют пациент-специфичные факторы, дополнительно искажающие МР-картину ПЖ, такие как наличие вмешательств на ПЖ и ее возрастные изменения [38].

Заключение

Несмотря на значимые достижения в автоматизации сегментации ПЖ с помощью алгоритмов глубокого обучения, до сих пор существует ряд проблем и ограничений, требующих дальнейшего развития и внедрения ИИ в клиническую практику.

ЛИТЕРАТУРА / REFERENCES

1. Коссов Ф.А., Черныев В.А., Ахвердиева Г.И. и др. Роль и значение мультипараметрической магнитно-резонансной томографии в диагностике рака предстательной железы. *Онкоурология* 2017;13(1):122–33. DOI: 10.17650/1726-9776-2017-13-1-122-133
2. Kossov P.A., Chernyaev V.A., Akhverdiev G.I. et al. Role and significance of multiparametric magnetic resonance imaging in prostate cancer diagnostics. *Onkourologiya = Cancer Urology* 2017;13(1):122–33. (In Russ.). DOI: 10.17650/1726-9776-2017-13-1-122-133
3. Beetz N.L., Haas M., Baur A. et al. Inter-reader variability using PI-RADS v2 versus PI-RADS v2.1: most new disagreement stems from scores 1 and 2. *Rofo* 2022;194(8):852–61. DOI: 10.1055/a-1752-1038
4. Ковалев В.А., Войнов Д.М., Малышев В.Д. и др. Компьютеризированная диагностика рака простаты на основе полнослайдовых гистологических изображений и методов глубокого обучения. *Информатика* 2020;17(4):48–60. DOI: 10.37661/1816-0301-2020-17-4-48-60
5. Kovalev V.A., Voinov D.M., Malyshev V.D. et al. Computerized diagnosis of prostate cancer based on whole slide histology images and deep learning methods. *Informatika = Informatics* 2020;17(4):48–60. (In Russ.). DOI: 10.37661/1816-0301-2020-17-4-48-60
6. Рева С.А., Шадеркин И.А., Зятчин И.В. и др. Искусственный интеллект в онкоурологии. *Экспериментальная и клиническая урология* 2021;14(2):46–51. DOI: 10.29188/2222-8543-2021-14-2-46-51
7. Reva S.A., Shaderkin I.A., Zyatchin I.V. et al. Artificial intelligence in cancer urology. *Ekspierimental'naya i klinicheskaya urologiya = Experimental and Clinical Urology* 2021;14(2):46–51. (In Russ.). DOI: 10.29188/2222-8543-2021-14-2-46-51
8. Da Silva G.L.F., Diniz P.S., Ferreira J.L. et al. Superpixel-based deep convolutional neural networks and active contour model for automatic prostate segmentation on 3D MRI scans. *Med Biol Eng Comput* 2020;58(9):1947–64. DOI: 10.1007/s11517-020-02199-5
9. Wang B., Lei Y., Tian S. et al. Deeply supervised 3D fully convolutional networks with group dilated convolution for automatic MRI prostate segmentation. *Med Phys* 2019;46(4):1707–18. DOI: 10.1002/mp.13416
10. Liu Q., Fu M., Gong X. et al. Densely dilated spatial pooling convolutional network using benign loss functions for imbalanced volumetric prostate segmentation. *Curr Bioinform* 2018;15(7):788–99. DOI: 10.48550/arXiv.1801.10517
11. Nai Y.H., Teo B.W., Tan N.L. et al. Evaluation of multimodal algorithms for the segmentation of multiparametric MRI prostate images. *Comput Math Methods Med* 2020;20:2020:8861035. DOI: 10.1155/2020/8861035
12. Yu L., Yang X., Chen H. et al. Volumetric ConvNets with mixed residual connections for automated prostate segmentation from 3D MR images. *Proc AAAI Conf Artif Intell* 2017;31(1):66–72. DOI: 10.1609/aaai.v31i1.10510
13. Comelli A., Dahiya N., Stefano A. et al. Deep learning-based methods for prostate segmentation in magnetic resonance imaging. *Appl Sci* 2021;11(2):1–13. DOI: 10.3390/app11020782
14. Karimi D., Samei G., Kesch C. et al. Prostate segmentation in MRI using a convolutional neural network architecture and training strategy based on statistical shape models. *Int J Comput Assist Radiol Surg* 2018;13(8):1211–9. DOI: 10.1007/s11548-018-1785-8
15. Ushinsky A., Bardis M., Glavis-Bloom J. et al. A 3D-2D Hybrid U-Net convolutional neural network approach to prostate organ segmentation of multiparametric MRI. *AJR Am J Roentgenol* 2021;216(1):111–6. DOI: 10.2214/AJR.19.22168
16. Yan K., Wang X., Kim J. et al. A propagation-DNN: deep combination learning of multi-level features for MR prostate segmentation. *Comput Methods Programs Biomed* 2019;170:11–21. DOI: 10.1016/j.cmpb.2018.12.031
17. Jia H., Xia Y., Song Y. et al. 3D APA-Net: 3D adversarial pyramid anisotropic convolutional network for prostate segmentation in MR images. *IEEE Trans Med Imaging* 2020;39(2):447–57. DOI: 10.1109/TMI.2019.2928056

15. Bardis M., Houshyar R., Chantaduly C. et al. Segmentation of the prostate transition zone and peripheral zone on MR images with deep learning. *Radiol Imaging Cancer* 2021;3(3):e200024. DOI: 10.1148/rycan.2021200024
16. Liu Y., Miao Q., Surawech C. et al. Deep learning enables prostate MRI segmentation: a large cohort evaluation with inter-rater variability analysis. *Front Oncol* 2021;11:801876. DOI: 10.3389/fonc.2021.801876
17. Nie D., Wang L., Gao Y. et al. STRAINet: Spatially-varying Stochastic Residual Adversarial Networks for MRI pelvic organ segmentation. *IEEE Trans Neural Networks Learn Syst* 2019;30(5):1552–64. DOI: 10.1109/TNNLS.2018.2870182
18. Sanford T.H., Zhang L., Harmon S.A. et al. Data augmentation and transfer learning to improve generalizability of an automated prostate segmentation model. *AJR Am J Roentgenol* 2020;215(6):1403–10. DOI: 10.2214/AJR.19.22347
19. Liu Q., Dou Q., Yu L. et al. MS-Net: Multi-Site Network for improving prostate segmentation with heterogeneous MRI data. *IEEE Trans Med Imaging* 2020;39(9):2713–24. DOI: 10.1109/TMI.2020.2974574
20. Wang W., Wang G., Wu X. et al. Automatic segmentation of prostate magnetic resonance imaging using generative adversarial networks. *Clin Imaging* 2021;70:1–9. DOI: 10.1016/j.clinimag.2020.10.014
21. Aldoj N., Biavati F., Michallek F. et al. Automatic prostate and prostate zones segmentation of magnetic resonance images using DenseNet-like U-net. *Sci Reports* 2020;10(1):14315. DOI: 10.1038/s41598-020-71080-0
22. Nhat To M.N.N., Vu D.Q., Turkbey B. et al. Deep dense multi-path neural network for prostate segmentation in magnetic resonance imaging. *Int J Comput Assist Radiol Surg* 2018;13(11):1687–96. DOI: 10.1007/s11548-018-1841-4
23. Zhu Q., Du B., Yan P. Boundary-weighted domain adaptive neural network for prostate MR image segmentation HHS public access. *IEEE Trans Med Imaging* 2020;39(3):753–63. DOI: 10.1109/TMI.2019.2935018
24. Zhu Y., Wei R., Gao G. et al. Fully automatic segmentation on prostate MR images based on cascaded fully convolution network. *J Magn Reson Imaging* 2019;49(4):1149–56. DOI: 10.1002/jmri.26337
25. Meyer A., Chlebus G., Rak M. et al. Anisotropic 3D multi-stream CNN for accurate prostate segmentation from multi-planar MRI. *Comput Methods Programs Biomed* 2021;200:105821. DOI: 10.1016/j.cmpb.2020.105821
26. Geng L., Wang J., Xiao Z. et al. Encoder-decoder with dense dilated spatial pyramid pooling for prostate MR images segmentation. *Comput Assist Surg* 2019;24(sup2):13–9. DOI: 10.1080/24699322.2019.1649069
27. Chen J., Wan Z., Zhang J. et al. Medical image segmentation and reconstruction of prostate tumor based on 3D AlexNet. *Comput Methods Programs Biomed* 2021;200:105878. DOI: 10.1016/j.cmpb.2020.105878
28. Yan L., Liu D., Xiang Q. et al. PSP net-based automatic segmentation network model for prostate magnetic resonance imaging. *Comput Methods Programs Biomed* 2021;207:106211. DOI: 10.1016/j.cmpb.2021.106211
29. Khan S., Vohra S., Farnan L. et al. Using health insurance claims data to assess long-term disease progression in a prostate cancer cohort. *Prostate* 2022;82(15):1447–55. DOI: 10.1002/pros.24418
30. Toth R., Madabhushi A. Multifeature landmark-free active appearance models: Application to prostate MRI segmentation. *IEEE Trans Med Imaging* 2012;31(8):1638–50. DOI: 10.1109/TMI.2012.2201498
31. Qiu W., Yuan J., Ukwatta E. et al. Dual optimization based prostate zonal segmentation in 3D MR images. *Med Image Anal* 2014;18(4):660–73. DOI: 10.1016/j.media.2014.02.009
32. Ghose S., Mitra J., Oliver A. et al. A random forest based classification approach to prostate segmentation in MRI. In: *MICCAI Gd. Chall. Prostate MR Image Segmentation*. 2012. Pp. 125–128.
33. Rundo L., Militello C., Russo G. et al. Automated prostate gland segmentation based on an unsupervised fuzzy C-means clustering technique using multispectral T1w and T2w MR imaging. *Inf* 2017;8(2):49. DOI: 10.3390/info8020049
34. Litjens G., Debats O., van de Ven W. et al. A pattern recognition approach to zonal segmentation of the prostate on MRI. *Med Image Comput Comput Assist Interv* 2012;15(Pt 2):413–20. DOI: 10.1007/978-3-642-33418-4_51
35. Jin J., Zhang L., Leng E. et al. Bayesian spatial models for voxel-wise prostate cancer classification using multi-parametric magnetic resonance imaging data. *Stat Med* 2022;41(3):483–99. DOI: 10.1002/sim.9245
36. Sharma N., Ray A.K., Shukla K.K. et al. Automated medical image segmentation techniques. *J Med Phys* 2010;35(1):3–14. DOI: 10.4103/0971-6203.58777
37. Chen D., Liu S., Kingsbury P. et al. Deep learning and alternative learning strategies for retrospective real-world clinical data. *NPJ Digit Med* 2019;2:43. DOI: 10.1038/s41746-019-0122-0
38. Bura V., Caglic I., Snoj Z. et al. MRI features of the normal prostatic peripheral zone: the relationship between age and signal heterogeneity on T2WI, DWI, and DCE sequences. *Eur Radiol* 2021;31(7):4908–17. DOI: 10.1007/s00330-020-07545-7

Вклад авторов

А.Э. Талышинский: автор идеи, сбор данных литературы, написание текста статьи;
 Б.Г. Гулиев, И.Г. Камышанская: автор идеи, сбор данных литературы, редактирование текста статьи;
 А.И. Новиков: автор идеи, редактирование текста статьи;
 У. Жанбырбекулы: сбор данных литературы, редактирование текста статьи;
 А.Э. Мамедов, И.А. Поваго, А.А. Андриянов: сбор данных литературы, написание текста статьи.

Authors' contributions

A.E. Talyshinskii: study idea, literature data accumulation, article writing;
 B.G. Guliev, I.G. Kamyshanskaya: study idea, literature data accumulation, article editing;
 A.I. Novikov: study idea, article editing;
 U. Zhanbyrbekuly: literature data accumulation, article editing;
 A.E. Mamedov, I.A. Povago, A.A. Andriyanov: literature data accumulation, article writing.

ORCID авторов / ORCID of authors

А.Э. Талышинский / A.E. Talyshinskii: <https://orcid.org/0000-0002-3521-8937>
 Б.Г. Гулиев / B.G. Guliev: <https://orcid.org/0000-0002-2359-6973>
 У. Жанбырбекулы / U. Zhanbyrbekuly: <https://orcid.org/0000-0003-1849-6924>
 А.Э. Мамедов / A.E. Mamedov: <https://orcid.org/0000-0002-6800-4505>
 И.А. Поваго / I.A. Povago: <https://orcid.org/0000-0002-3145-0245>
 А.А. Андриянов / A.A. Andriyanov: <https://orcid.org/0000-0001-6905-0581>

Конфликт интересов. Авторы заявляют об отсутствии конфликта интересов.
Conflict of interest. The authors declare no conflict of interest.

Финансирование. Работа выполнена без спонсорской поддержки.
Funding. The work was performed without external funding.