

ОНКОЛОГИЯ

УДК 004.89

**Применение искусственного интеллекта
в обнаружении и стратификации рака предстательной
железы: обзор литературы***А. Э. Талышинский^{1,2}, И. Г. Камышанская^{2,3}, А. В. Мищенко^{2,4,5},
Б. Г. Гулиев³, Р. Ф. Бахтиозин⁶*¹ Медицинский университет Астана,

Республика Казахстан, 010000, Астана, ул. Бейбитшилик, 49а

² Санкт-Петербургский государственный университет,

Российская Федерация, 199034, Санкт-Петербург, Университетская наб., 7–9

³ Санкт-Петербургская городская Мариинская больница,

Российская Федерация, 191014, Санкт-Петербург, Литейный пр., 56

⁴ Российская медицинская академия непрерывного профессионального образования,

Российская Федерация, 125993, Москва, ул. Баррикадная, 2/1

⁵ Научно-медицинский исследовательский центр онкологии им. Н. Н. Петрова,

Российская Федерация, 197758, Санкт-Петербург, ул. Ленинградская, 68

⁶ Первый Московский государственный медицинский университет им. И. М. Сеченова (Сеченовский университет),

Российская Федерация, 119048, Москва, ул. Трубецкая, 8

Для цитирования: Талышинский А. Э., Камышанская И. Г., Мищенко А. В., Гулиев Б. Г., Бахтиозин Р. Ф. Применение искусственного интеллекта в обнаружении и стратификации рака предстательной железы: обзор литературы // Вестник Санкт-Петербургского университета. Медицина. 2023. Т. 18. Вып. 2. С. 150–166. <https://doi.org/10.21638/spbul1.2023.204>

В обзоре литературы проанализированы современные подходы в использовании искусственного интеллекта для обнаружения и стратификации рака предстательной железы по данным магнитно-резонансной томографии. Приведен анализ объема данных, используемых для обучения и валидации искусственных нейросетей, а также наиболее востребованные последовательности магнитно-резонансного исследования предстательной железы для машинного и глубокого обучения интеллектуальных систем. Представлены показатели точности включенных в обзор нейросетей в решении поставленных задач, а также дано их краткое описание. Определены недостатки современных работ по разработке нейросетей для обнаружения и стратификации рака предстательной железы по данным магнитно-резонансной томографии, а также труд-

ности их разработки и применения. Представленный всесторонний анализ углубляется в существующие подходы к использованию искусственного интеллекта для обнаружения и стратификации рака предстательной железы с помощью данных магнитно-резонансной томографии. Анализ касается масштаба данных и предпочтительных последовательностей магнитно-резонансной томографии, используемых для обучения нейронной сети. В обзоре представлена разбивка показателей точности для оцениваемых нейронных сетей с разъяснением их соответствующих возможностей. Кроме того, в обзоре выявляются недостатки работ, описывающих текущие модели нейронных сетей, разработанных для обнаружения и стратификации рака предстательной железы с помощью магнитно-резонансной томографии, а также признаются сложности, связанные с их разработкой и практическим применением.

Ключевые слова: рак предстательной железы, МРТ, искусственный интеллект.

Введение

Рак предстательной железы (РПЖ) является одним из наиболее распространенных онкологических заболеваний мужчин во всем мире. Несмотря на непрерывное развитие диагностических возможностей и алгоритмов, сохраняется проблематика выполнения ненужных биопсий и радикального лечения при индолентных новообразованиях [1] и активное наблюдение за пациентами с клинически значимыми формами. Это связано с широкой вариабельностью степени злокачественности рака предстательной железы и различием в интерпретации снимков мультипараметрической магнитно-резонансной томографии (мпМРТ) разными специалистами [2].

Искусственный интеллект (ИИ) в здравоохранении — область развития, оптимизирующая процесс принятия решений специалистами различного профиля на всех этапах ведения больных [3]. Что касается рака предстательной железы, то наиболее популярным методом применения ИИ является именно интерпретация снимков мпМРТ. Несмотря на широкую вариабельность и известность данного направления, в отечественной литературе крайне мало исследований, посвященных как разработке и апробации методов машинного и глубокого обучения для решения вышеупомянутых проблем, так и обзору современного состояния ИИ [4]. В свете вышесказанного целью данной работы явилось описание всех имеющихся подходов в машинном и глубоком обучении для обнаружения, стратификации и сегментации РПЖ.

Материалы и методы

Поиск публикаций проводился в декабре 2022 г. в системе PubMed при помощи клинического запроса: (AI) OR (machine learning) OR (deep learning) AND (prostate) AND (MRI). Критериями включения были: описание метода машинного или глубокого обучения для выявления и определения рака предстательной железы, доступность полной статьи, дата публикации не более пяти лет на момент поиска, наличие количественной оценки точности в виде площади под характеристической кривой (AUC). Помимо этого, анализировали список литературы в отобранных для ознакомления статьях. В обзор литературы включали статьи, акцентированные на сравнении различных алгоритмов, при анализе которых в таблицу вносились результаты по наиболее оправданному методу обучения.

Описательная статистика реализовывалась с помощью программного обеспечения (ПО) SPSS Statistics 26.0. Определение распределения непрерывных данных осуществляли с помощью теста Колмогорова — Смирнова, после чего рассчитывали среднее значение со стандартным отклонением или медиану с минимальным и максимальными значениями в зависимости от нормализованности.

Результаты

В результате поиска необходимых публикаций было найдено 535 статей, из которых в анализ включено 38 работ с описанием 40 различных методов применения машинного или глубокого обучения.

Машинное обучение в обнаружении и определении РПЖ

В группу публикаций по машинному обучению в обнаружении и стратификации РПЖ вошло 15 работ. В ходе анализа публикаций обращалось внимание на используемые в них классификаторы; количество исследований для обучения, валидации и тестирования; включенные в анализ последовательности МРТ и точность предлагаемого подхода в виде коэффициента Соренсена — Дайса (табл. 1).

Как видно из табл. 1, путем анализа изучаемых показателей определено, что количество исследований для обучения, валидации и тестирования в среднем составило $117,3 \pm 92,6$ с диапазоном от 17 до 344. Среди последовательностей в мпМРТ использовали Т2ВИ в 14 работах, ДВИ — в 7, ИКД — в 9, ДКУ — в 5 и диффузионно-тензорная визуализация в 1 публикации. Средняя точность составила $0,899 \pm 0,07$. Наиболее оправданными классификаторами являлись: машина опорных векторов (6 статей), случайный лес (3 статьи), логистическая регрессия (3 статьи), иерархическая кластеризация (1 статья), XGBoost (1 статья) и байесовская сеть (1 статья).

В работе J. Wang и соавт. [5] продемонстрировано обучение с помощью 40 радиомических признаков и машины опорных векторов. Добавление к данной модели PI-RADS v2 позволило достичь точности выявления клинически значимого РПЖ в периферической и переходной зонах 0,983 и 0,968 соответственно.

В исследовании C. Alvarez-Jimenez и соавт. [6] при сравнении трех классификаторов (машина опорных векторов, Adaboost и случайный лес) было определено преимущество первого с возможностью достижения AUC до 0,91 в диагностике клинически значимого РПЖ в области передней фибромышечной стромы, 0,85 — в периферической зоне и 0,87 — в переходной зоне.

R. Suocolo и соавт. [7] апробировали машину опорных векторов с использованием 14 радиомических показателей для определения экстрапростатического распространения РПЖ. В обучающей и двух тестовых выборках достигнуто значение площади под характеристической кривой, равной 0,83, 0,80 и 0,73 соответственно.

N. Gholizadeh и соавт. [8] использовали машину опорных векторов для характеристики злокачественных очагов предстательной железы посредством радиомической оценки вокселей в Т2ВИ-взвешенном изображении, ДВИ и диффузионно-тензорной визуализации, рассчитанной по ДВИ-изображениям с b-фактором, равным 0 с/мм^2 с помощью афинного и ригидного преобразования. Согласно результатам, комбинация всех трех последовательностей мпМРТ приводила к AUC,

Таблица 1. Статьи о применении машинного обучения в обнаружении и стратификации РПЖ

Авторы	Классификатор	Количество исследований	Последовательности мпМРТ	Коэффициент Соренсена — Дайса
J. Wang и соавт. [5]	Машина опорных векторов	54	T2ВИ, ДВИ	0,983
C. Alvarez-Jimenez и соавт. [6]	Машина опорных векторов	84	T2ВИ	0,91
R. Suocolo и соавт. [7]	Машина опорных векторов	193	T2ВИ, ИКД	0,80
N. Gholizadeh и соавт. [8]	Машина опорных векторов	17	T2ВИ, ДВИ, ДТ	0,93
V. Giannini и соавт. [9]	Машина опорных векторов	131	T2ВИ, ДВИ, ИКД, ДКУ	0,81
B. Varghese и соавт. [10]	Машина опорных векторов	121	T2ВИ, ИКД	0,92
D. Kwon и соавт. [11]	Случайный лес	344	T2ВИ, ДВИ, ИКД, ДКУ	0,82
S. J. Hectors и соавт. [12]	Случайный лес	240	T2ВИ	0,76
L. Zhang и соавт. [13]	Случайный лес	142	T2ВИ и ДВИ	0,918
B. Liu и соавт. [14]	Логистическая регрессия	40	T2ВИ, ИКД, ДКУ	0,93
M. Wu и соавт. [15]	Логистическая регрессия	44	T2ВИ, ИКД	0,989
Y. Iyama и соавт. [16]	Логистическая регрессия	60	T2ВИ, ИКД	0,97
Y. Akamine и соавт. [17]	Иерархическая кластеризация	52	ДВИ, ДКУ	0,978
S. Liu и соавт. [18]	XGBoost	199	T2ВИ, ДВИ, ИКД, ДКУ	0,89
A. Stanzione и соавт. [19]	Байесовская сеть	39	T2ВИ, ИКД	0,88

Примечание: T2ВИ — T2-взвешенные изображения; ДВИ — диффузионно-взвешенные изображения; ИКД — измеряемый коэффициент диффузии; ДКУ — динамическое контрастное усиление.

равной 0,93, при этом использование только снимков в T2ВИ-взвешенном изображении и ДВИ приводило к снижению точности на 3,52 %.

V. Giannini и соавт. [9] описали использование машины опорных векторов для дифференциации РПЖ с индексом Глисона ≤ 2 и > 2 с помощью четырех радиомических признаков. Согласно их результатам, при валидации сети получено значение AUC, равное 0,81.

B. Varghese и соавт. [10] проанализировали точность различных классификаторов машинного обучения (логистическая регрессия, случайный лес, линейный дискриминантный анализ, вариации машины опорных векторов) при использовании

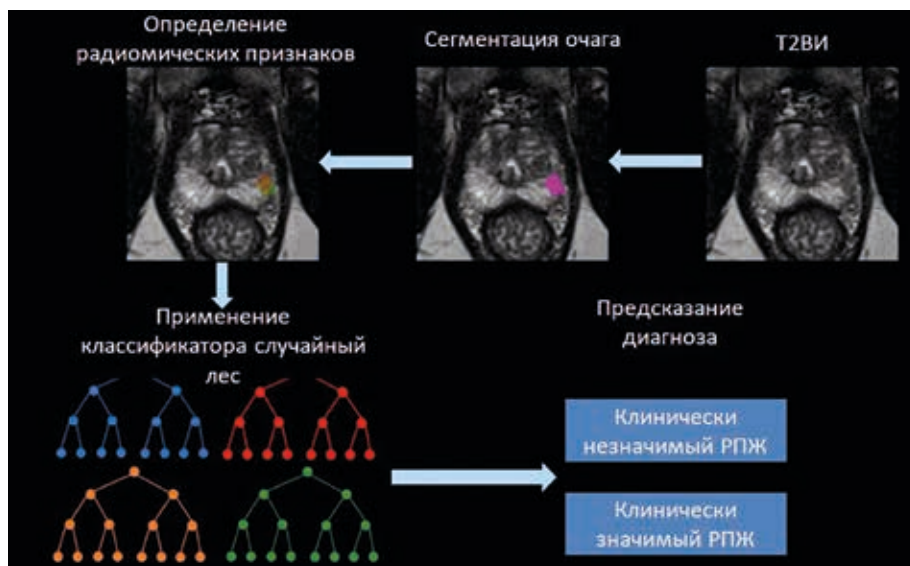


Рис. 1. Алгоритм анализа изображений.
Составлено по: [12]

55 радиомических признаков в диагностике и стратификации РПЖ, а также сравнили точность наиболее информативного подхода с результатами интерпретации снимков рентгенологами по шкале PI-RADS v2. Согласно их результатам, кубическая машина опорных векторов обеспечивает AUC до 0,92 и превосходит результаты субъективной оценки специалистов.

D. Kwon и соавт. [11] сравнили точность трех классификаторов (классификационные и регрессионные деревья (CART), случайный лес и Лассо Тибширани (LASSO)) с использованием радиомических признаков трех категорий в обнаружении РПЖ переходной и периферической зон. Во время тестирования на открытом датасете получены следующие показатели AUC: 0,76, 0,82 и 0,76 соответственно перечисленным подходам.

S. J. Hectors и соавт. [12] изучили точность выявления такого клинически значимого РПЖ классификатора, как случайный лес, а также сравнили полученные результаты с результатами использования плотности простат-специфического антигена (ПСА) и объема предстательной железы. Алгоритм анализа изображений в данной работе представлен на рис. 1. После сортирования T2ВИ-взвешенных изображений проводилось ручное контурирование патологических очагов с последующим расчетом радиомических параметров контурированной области путем сопоставления этих параметров с результатами гистологической верификации. При помощи случайного леса проводилось разграничение радиомических признаков, соответствующих клинически незначимому и значимому РПЖ.

Достаточным являлось использование лишь T2ВИ-взвешенных изображений, что позволяло достигать AUC, равный 0,76, значимо превосходя плотность ПСА и объем предстательной железы (0,62 и 0,61 соответственно).

L. Zhang и соавт. [13] сравнили точность трех классификаторов (случайный лес, логистическая регрессия и машина опорных векторов) в разграничении РПЖ

высокого и низкого риска с помощью обучения по восьми радиомическим показателям. В тренировочном датасете достигнуты следующие значения AUC: 0,918; 0,886; 0,913, что во всех случаях значимо превосходило заключение рентгенологов по PI-RADS v2.1 (0,813).

В. Liu и соавт. [14] использовали три тестовых датасета для оценки эффективности прогнозирования степени дифференцировки РПЖ перед биопсией предстательной железы следующих классификаторов: машина опорных векторов на основе линейного ядра, логистическая регрессия, случайный лес, древо решений и метод k-ближайших соседей. В отличие от предыдущей работы, наилучший результат был достигнут с применением логистической регрессии (AUC = 0,93).

М. Wu и соавт. [15] оценивали эффективность логистической регрессии и машины опорных векторов с применением текстурных признаков Т2ВИ и ИКД-изображений в обнаружении РПЖ переходной зоны. В качестве результатов многофакторного анализа было отобрано четыре наиболее информативных радиомических признака, что позволило достичь значений AUC, чувствительности и специфичности, равных 0,989 / 93,2 % / 98,4 % и 0,949 / 93,2 % / 96,7 % соответственно.

Аналогично предыдущей работе Y. Yuama и соавт. [16] описали применение логистической регрессии в определении РПЖ в переходной зоне. В процессе работы изучались такие параметры, как нормализованный сигнал Т2, асимметрия Т2, эксцесс Т2, асимметрия ИКД, эксцесс ИКД, среднее и минимальное значение ИКД, из которых использование нормализованного Т2ВИ-сигнала и его асимметрия, а также среднее значение ИКД позволяет достигать AUC, равной 0,97, что было сопоставимо с результатами опытных рентгенологов.

Y. Akamine и соавт. [17] продемонстрировали результаты применения иерархической кластеризации для разграничения нормальной и злокачественной ткани предстательной железы в периферической и переходной зонах. Точность диагностики составила 0,96 и 0,97 соответственно.

S. Liu и соавт. [18] с помощью градиентного бустинга XGBoost классифицировали 87 радиомических показателей, включая средние значения и стандартные отклонения интенсивностей, а также особенности текстуры, такие как энергия, контраст и т. д. для выявления РПЖ по Т2ВИ, ДВИ, ИКД и ДКУ снимкам. В тестовом наборе значения AUC, чувствительности и специфичности составили 0,89, 87 %, 77 % соответственно.

A. Stanzone и соавт. [19] апробировали различные классификаторы (древо решений, случайный лес, машина опорных векторов, метод k-ближайших соседей, байесовская сеть и наивный байесовский классификатор) с помощью 21 радиомического признака. Согласно результатам, наилучшие показатели достигнуты при использовании байесовской сети (AUC = 0,88).

Глубокое обучение нейросетей обнаружению и определению злокачественности РПЖ

Методы глубокого обучения нейросетей диагностике рака предстательной железы описаны в 25 работах. Отобранные статьи приведены в табл. 2 с описанием определяемых параметров: используемых нейросетей, количества исследований для обучения, валидации и тестирования, включенных в анализ последователь-

Таблица 2. Исследования в области применения методов глубокого обучения нейросетей обнаружению и стратификации РПЖ в соответствии с его клинической значимостью

Авторы	Алгоритм	Количество исследований	Последовательности	Точность
J. Ishioka и соавт. [20]	U-net + ResNet50	335	T2ВИ	0,645
C. Alvarez-Jimenez и соавт. [6]	Inception V3	84	T2ВИ	0,79
F. Zabihollahy и соавт. [21]	U-Net	226	ИКД	0,779
A. Mehrtash и соавт. [22]	9-слойная 3D CNN	344	T2ВИ, ДВИ, ИКД, ДКУ	0,80
A. Saha и соавт. [23]	3D U-Net + остаточный классификатор	2137	T2ВИ, ДВИ, ИКД	0,885
Q. Chen и соавт. [24]	VGG-16	344	T2ВИ, ДВИ, ДКУ	0,83
P. Sobocki и соавт. [25]	3D VGG-16	344	T2ВИ, ДВИ, ИКД, ДКУ	0,84
J. Sanyal и соавт. [26]	Модель из двух U-Net сетей	77	T2ВИ, ДВИ, ИКД	0,86
I. Bhattacharya и соавт. [27]	CorrSigNet	95	T2ВИ, ИКД	0,86
X. Yu и соавт. [28]	Res-UNet + 2,5D сеть	2170	T2ВИ, ДВИ, ИКД	0,867
S. Yoo и соавт. [29]	ResNet	427	ИКД	0,87
X. Zhong и соавт. [30]	ResNet	140	T2ВИ, ИКД	0,876
P. Khosravi и соавт. [31]	GoogLeNet	400	T2ВИ	0,89
M. Arif и соавт. [32]	12-слойная CNN	292	T2ВИ, ДВИ, ИКД	0,89
Z. Wang и соавт. [33]	Сеть деформации тканей (TDN) + двунаправленная сверточная нейронная сеть	360	T2ВИ, ИКД	0,898
I. R. Abdelmaksoud и соавт. [34]	VGGnet	37	ДВИ	0,91
N. Aldoj и соавт. [35]	12-слойная CNN	200	ДВИ, ИКД, КДУ	0,91
Y. Song и соавт. [36]	Модификация VGGNet	195	T2ВИ, ДВИ, ИКД	0,944
S. Liu и соавт. [18]	XmasNet	204	T2ВИ, ДВИ, ИКД, ДКУ	0,95
O. J. Pellicer-Valero и соавт. [37]	3D Retina U-Net	490	T2ВИ, ДВИ, ИКД, ДКУ	0,96
H. Xu и соавт. [38]	ResNet	346	T2ВИ, ДВИ, ИКД	0,97
L. Brunese и соавт. [39]	10-слойная сверточная нейронная сеть	72	T2ВИ	0,98
R. Cao и соавт. [40]	FocalNet	417	T2ВИ, ИКД	0,81
Y. Hou и соавт. [41]	ResNeXt	840	T2ВИ, ДВИ, ИКД	0,857
W. Zong и соавт. [42]	«Vanilla» VGG	201	T2ВИ, ДВИ, ИКД	0,91

ностей МР-исследования и точности предлагаемой модели в виде площади под характеристической кривой.

Из табл. 2 видно, что медиана количества исследований для обучения, валидации и тестирования составила 335 с диапазоном от 37 до 2170. Среди последовательностей мпМРТ, Т2ВИ-взвешенное изображение используется в 21 работе, ДВИ — в 16, ИКД — в 18, ДКУ — в 5. Средняя точность составила $0,871 \pm 0,07$.

В статье J. Ishioka и соавт. [20] использована архитектура сверточной нейронной сети (*англ.* convolutional neural network, CNN), сочетающую U-net и ResNet50 модели. При апробации на двух тестовых датасетах достигнуто значение AUC, равное 0,645 и 0,636 соответственно.

F. Zabihollahy и соавт. [21], используя ИКД 226 пациентов, рассчитанные по ДВИ с b-фактором 0, 500, и 1000 с/мм², описывают применение трех параллельных U-Net сетей для выявления рака предстательной железы. Итоговое значение AUC, чувствительности и специфичности для комбинированной сети составили 0,779, 85,76 % и 76,44 %.

A. Mehrtash и соавт. [22] реализовали трехмерную CNN с тремя входными потоками: ИКД-карты, ДВИ при максимальном значении диффузионного фактора и Ktrans по ДКУ. Была оценена эффективность различных комбинаций входных данных мпМРТ для изучаемой архитектуры, и наилучший результат был достигнут с использованием ДВИ и ДКУ вместе с зональной информацией по Т2ВИ-взвешенным изображениям. При тестировании модель достигла площади, равной 0,80, под характеристической кривой.

A. Saha и соавт. [23] описали архитектуру из двух параллельных CNN (M1, M2). Согласно результатам, эта архитектура при использовании обеих сетей достигает в идентификации РПЖ значения AUC, в среднем равного 0,885, что значимо выше, чем при использовании таких 3D сетей, как Attention U-Net, nnU-Net, UNet++ и U-SEResNet (0,861, 0,872, 0,850, 0,856, 0,500 соответственно).

Q. Chen и соавт. [24] описали трансферное глубокое обучение посредством сетей InceptionV3 и VGG-16 для обнаружения РПЖ по Т2ВИ, ДВИ и ДКУ снимкам. Метод трансферного обучения состоит в адаптации сети, разработанной для смежной задачи. Согласно результатам авторов, модель InceptionV3 достигла под кривой площади, равной 0,81, а VGG-16 — равной 0,83.

P. Sobocki и соавт. [25] разработали модель на основе базовой сети VGG-16 путем введения 3D-сверточных слоев вместо 2D-слоев. Т2-изображения в сагиттальной, коронарной и аксиальной плоскостях, а также снимки ДВИ, ИКД и КДУ обрабатывались независимо друг от друга в отдельных 3D-слоях. Оптимизированная модель с кодированием знаний при обучении достигла несколько лучших результатов классификации по сравнению с традиционной архитектурой (AUC = 0,84 против AUC = 0,82).

J. Sanyal и соавт. [26] описали модель двухэтапной сверточной нейронной сети из двух U-Net сетей. Первая отвечала за сегментацию предстательной железы, вторая осуществляла обнаружение клинически значимого РПЖ. Описанная архитектура достигала AUC, равной 0,86.

I. Bhattacharya и соавт. [27] описали CorrSigNet, учитывающую на этапе обучения не только снимки Т2ВИ и ИКД, но и изображения гистологических срезов. Итоговая точность составила 0,86.

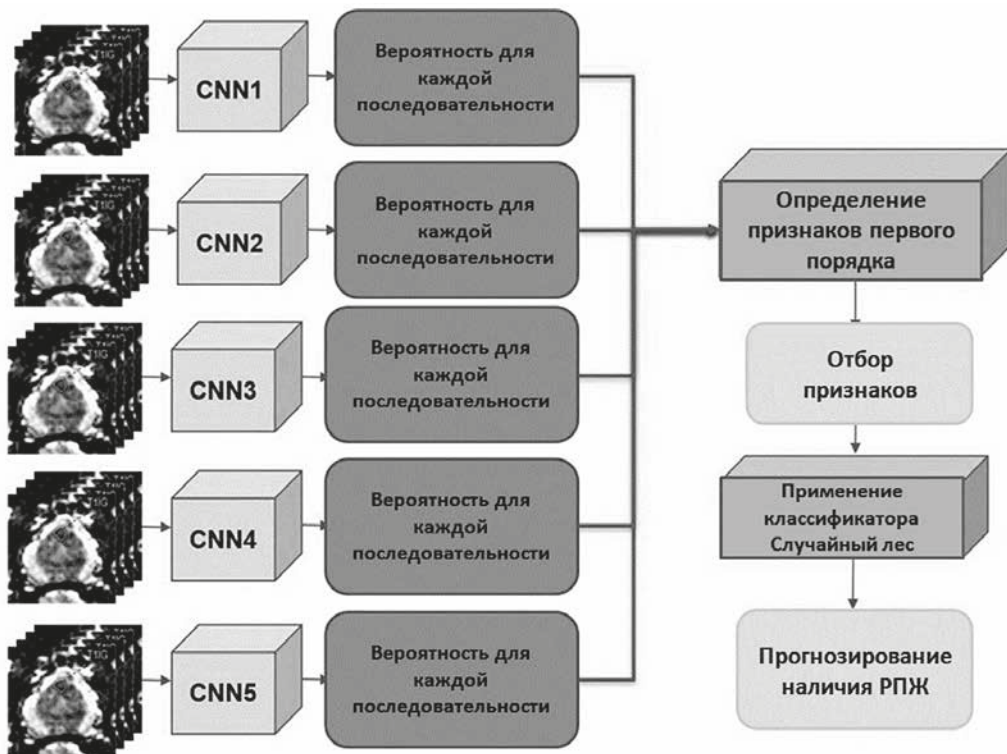


Рис. 2. Схема мультикомпонентной нейросети.
Составлено по: [29]

Х. Yu и соавт. [28] описали архитектуру Res-UNet. Уменьшение ложноположительных результатов осуществлялось дополнительной 2,5D сетью.

S. Yoo и соавт. [29] в качестве сети выбрали модификацию ResNet. Для анализа ДВИ снимков с соответствующим диффузионным фактором (0, 100, 400, 1000, 1600 с/мм²) использовались пять сверточных нейронных сетей (рис. 2). Входными данными для пяти CNN являются ИКД изображения размером 66 × 66 × 6, соответствующие b-фактору со значениями 0 с/мм², 100 с/мм², 400 с/мм², 1000 с/мм², 1600 с/мм². Путем параллельного анализа ДВИ снимков с разными значениями b-фактора определяется вероятность наличия рака предстательной железы, что в последующем, для взаимного увеличения точности прогнозирования, интегрируется в единую прогностическую модель на основе глубокого обучения.

В публикации X. Zhong и соавт. [30] использована нейросеть ResNet с трансферным обучением для разграничения клинически незначимых и значимых очагов РПЖ, а также проведено сравнение ее эффективности с эффективностью стандартной сверточной нейронной сети и PI-RADS v2. Согласно результатам, для различения индолентного новообразования и клинически значимых поражений с помощью модели с трансферным обучением, без него и с применением оценки PI-RADS v2 значения площади под характеристической кривой составили 0,726, 0,687 и 0,711 соответственно. При этом разница между трансферным обучением и PI-RADS v2 была статистически незначима.

P.Khosravi и соавт. [31] использовали архитектуру Google Inception-V128 (GoogLeNet). Авторы преследовали две цели: дифференциацию опухолей от здоровых тканей путем формирования Глисон группы (GG) 3, 4 и 5, а также определение только клинически значимых очагов (путем объединения GG 1, 2 и 3, 4, 5 в разные группы соответственно). Предлагаемый алгоритм способен идентифицировать опухоль ПЖ и, в частности, выделять клинически значимые очаги со значениями AUC, чувствительности и специфичности 0,89, 81,5 %, 82 % и 0,78, 71,3 %, 68,9 % соответственно.

M. Arif и соавт. [32] описывают опыт применения глубокого обучения по Т2ВИ, ДВИ (b-фактор = 800 с/мм²) и ИКД снимкам в выявлении и сегментации клинически значимого рака предстательной железы и в подтверждении рака низкого риска (степень ISUP ≤ 1) у пациентов, находящихся под активным наблюдением. AUC, чувствительность и специфичность достигали диапазона 0,65–0,89, 82–92 % и 43–76% соответственно.

Z. Wang и соавт. [33] описали использование нейронной сети, состоящей из объединенных подсетей: 1) сети деформации тканей (TDN) для автоматического обнаружения предстательной железы и 2) двунаправленной CNN для обнаружения клинически-значимого РПЖ (кзРПЖ). На этапе обучения две сети взаимно влияют друг на друга и эффективно направляют регистрацию и извлечение репрезентативных признаков. Согласно результатам авторов, комбинация Т2ВИ и ИКД изображений более оправдана и позволяет достигать AUC, равной 0,898.

I.R. Abdelmaksoud и соавт. [34] оценили диагностическую точность сетей AlexNet и VGGNet с помощью ДВИ изображений, полученных при использовании девяти диффузионных факторов (100, 200, 300, 400, 500, 600, 700, 800 и 900 с/мм²). Средняя чувствительность и специфичность AlexNet составила 87,5 ± 2,3 % и 90,9 ± 1,9 %. Эти результаты улучшились при использовании более глубокой модели CNN (VGGNet), достигая значений 91,7 ± 1,7 % и 90,1 ± 2,8 % соответственно.

N. Aldoј и соавт. [35] апробировали 3D сверточную нейронную сеть с отдельными входными слоями для Т2ВИ, ДВИ, ИКД и ДКУ изображений, нацеленными на диагностику РПЖ. Значение AUC достигало 0,91 при использовании изображений ДВИ, ИКД и КДУ, при этом применение Т2ВИ-взвешенного изображения не приводило к каким-либо улучшениям.

Y. Song и соавт. [36] модифицировали VGGNet и разработали архитектуру глубокой сверточной нейронной сети (DCNN). Обучение проводилось с помощью Т2ВИ и ДВИ и ИКД изображений 195 пациентов. Точность разграничения опухолевой и здоровой ткани составила 0,944 с чувствительностью 87,0 % и специфичностью 90,6 %.

O. J. Pellicer-Valero и соавт. [37] апробировали сеть 3D Retina U-Net, объединяющую одноступенчатую RetinaNet и U-Net, для обнаружения и стратификации опухоли предстательной железы. Согласно результатам, подобная архитектура нейросети приводила к AUC, чувствительности и специфичности, равным 0,96, 100 % и 79 % соответственно.

H. Xu и соавт. [38] использовали остаточную нейронную сеть ResNet для автоматизированной диагностики РПЖ по снимкам Т2ВИ, ДВИ и ИКД.

L. Brunese и соавт. [39] использовали модифицированную CNN с включением 71 радиомического признака Т2ВИ-взвешенных изображений, разделенных на

пять групп. Точность выявления и стратификации опухоли варьировала от 0,96 до 0,98.

R. Сао и соавт. [40] описали использование FocalNet — сквозной многоклассовой CNN, симультанно определяющей очаг поражения и степень его злокачественности по Глиссону путем принятия T2ВИ и ИКД изображений в два входных канала и прогнозирования на уровне пикселей метки шести классов: «поражения нет», GS 3+3, GS 3+4, GS 4+3, GS = 8 и GS ≥ 9. Для обнаружения только клинически значимых поражений была достигнута площадь под характеристической кривой, равная 0,81.

У. Ноу и соавт. [41] описали двухмерную сверточную нейронную сеть ResNeXt с модулем сверточного блочного внимания (CBAM) для анализа изображений мпМРТ путем совместного использования режимов T2ВИ, ДВИ со значением диффузионного фактора 1500 с/мм² и ИКД. W. Zong и соавт. [42] использовали «vanilla» сверточную нейронную сеть типа VGG. Средние значения AUC, чувствительности и специфичности составили 0,91, 100% и 83% и были максимальными при комбинации T2ВИ, ДВИ и ИКД изображений.

Обсуждение

Рак предстательной железы во всем мире занимает лидирующие позиции в структуре мужской заболеваемости и смертности от злокачественных новообразований [43]. Несмотря на анатомо-функциональную визуализацию предстательной железы при выполнении мпМРТ и на наличие протокола унифицирования интерпретации в виде PI-RADS v2 / v2.1, до сих пор сохраняется проблематика различия в заключениях разных специалистов, анализирующих снимки одного пациента, выполнения ненужных биопсий предстательной железы и упущения при ее выполнении доминантных и наиболее злокачественных очагов, приводящего к неправильной стратификации больных.

Одним из способов решения этих проблем является применение вычислительных алгоритмов, в частности искусственного интеллекта. В медицине использование данного направления в основном реализовано посредством алгоритмов машинного и глубокого обучения. Однако, несмотря на впечатляющие результаты включенных в обзор исследований, существуют исследования и с обратным результатом.

P. Schelb и соавт. [44] показали, что заключение рентгенологов не уступало U-Net сети в точности обнаружения и определении вероятности клинической значимости РПЖ.

S. Y. Youn и соавт. [45] сравнили точность системы Prostate AI (Siemens Health-care) с результатами рентгенологов, разделенных на подгруппы в зависимости от опыта интерпретации мпМРТ. Лишь заключение специалистов с наименьшим опытом уступало оценке Prostate AI, в то время как наиболее опытные рентгенологи достигали достоверно большую точность. То же самое представлено в работе T. Sanford и соавт. [46], сравнивающих оценку PI-RADS v2 с результатами ResNet сети.

В основе вышеупомянутых несоответствий лежат несколько проблем, ограничивающих определение преимуществ и перспектив активного внедрения ИИ-систем в клиническую практику.

Во-первых, направление искусственного интеллекта является постоянно и бурно развивающимся, что не позволяет определять «золотой стандарт» архитектуры

сети. Помимо этого, в исследованиях наблюдаются различия в реализации этапа сбора, подготовки и интерпретации данных. В работе М. Н. Le и соавт. [47] показано, что разница в точности выявления клинически значимого рака предстательной железы между тремя архитектурами глубокого обучения (VGGNet, GoogLeNet и ResNet) относительно невелика и зависит от методов слияния и аугментации данных. Целью последней является «компенсация» ограниченного количества доступных изображений и приближения распределения выборки к истинному. Это необходимо не только для увеличения абсолютного числа данных при обучении, но и для их репрезентативности [48]. В свою очередь, при машинном обучении наиболее информативным подходом в получении данных является определение невидимых человеческому глазу радиомических признаков (форма, объем, поверхность и текстура), соответствующих количественным показателям изображений [49]. Однако этот процесс требует значимых усилий по тщательному проектированию объектов перед обучением классификаторов.

Во-вторых, при выполнении мпМРТ в стационарах используются различные настройки аппаратуры, что требует предварительного предпроцессинга данных для их обобщения перед обучением сетей. Помимо этого, несмотря на весомый мировой задел в рамках разработки алгоритмов ИИ для диагностики рака предстательной железы, не определена наиболее информативная комбинация режимов мпМРТ, что отображено в нашем обзоре. В частности, только в 29 работах используются ИКД данные. Согласно исследованию D. Bonekamp и соавт. [50], использование лишь ИКД изображений достаточно для успешного определения клинически значимого рака предстательной железы как в периферической, так и в переходной зоне, без каких-либо дополнительных преимуществ при использовании машинного обучения, а также при добавлении данных Т2ВИ режима. Помимо этого, в мета-анализе Н. J. Meuer и соавт. [51] показано, что среди всех режимов мпМРТ именно ИКД наиболее достоверно коррелирует со шкалой Глисона.

В-третьих, сама природа рака предстательной железы определяет сложность применения ИИ для его инструментальной интерпретации. В большинстве работ обнаруживается только доминантный очаг, что не позволяет определять истинную степень поражения предстательной железы. Помимо этого, хотя в большинстве работ основной задачей ставится обнаружение опухоли в пределах всей предстательной железы, в когорте обучения преобладают случаи локализации очага в периферической зоне. Рак переходной зоны предстательной железы является распространенной клинической проблемой, на долю которой приходится до 20 % всех случаев РПЖ.

Наконец, практически все работы направлены на интерпретацию непосредственно зоны очага, в то время как без внимания остается так называемая перитуморальная зона. Согласно A. Algohary и соавт. [52], определение радиомических признаков данной локализации при использовании машинного обучения приводит к увеличению точности диагностики клинически значимого рака предстательной железы на 3–6 %.

Заключение

Применение искусственного интеллекта в анализе мпМРТ изображений пациентов с подозрением на рак предстательной железы является многообещающим

инструментом для более эффективной их интерпретации. Однако многообразие строения нейросетей, неопределенность в выборе режимов мПМРТ и клинко-лабораторных данных для их обучения диктуют необходимость дальнейших исследований для решения данных ограничений.

Литература / References

1. Shatylo T. V., Popkov V. M., Fomkin R. N. Integrative approach to pre-operative determination of clinically significant prostate cancer. *Saratovskii nauchno-meditsinskii zhurnal*, 2015, vol. 11, no. 3, pp. 345–348. (In Russian)
2. Westphalen A. C., McCulloch C. E., Anaokar J. M., Arora S., Barashi N. S., Barentsz J. O., Bathala T. K., Bittencourt L. K., Booker M. T., Braxton V. G., Carroll P. R., Casalino D. D., Chang S. D., Coakley F. V., Dhatt R., Eberhardt S. C., Foster B. R., Froemming A. T., Fütterer J. J., Ganeshan D. M., Gertner M. R., Mankowski Gettle L., Ghai S., Gupta R. T., Hahn M. E., Houshyar R., Kim C., Kim C. K., Lall C., Margolis D. J. A., McRae S. E., Oto A., Parsons R. B., Patel N. U., Pinto P. A., Polascik T. J., Spilseth B., Starcevic J. B., Tammisetti V. S., Taneja S. S., Turkbey B., Verma S., Ward J. F., Warlick C. A., Weinberger A. R., Yu J., Zagoria R. J., Rosenkrantz A. B. Variability of the Positive Predictive Value of PI-RADS for Prostate MRI across 26 Centers: Experience of the Society of Abdominal Radiology Prostate Cancer Disease-focused Panel. *Radiology*, 2020, vol. 296, no. 1, pp. 76–84.
3. Harish V., Morgado F., Stern A. D., Das S. Artificial Intelligence and Clinical Decision Making: The New Nature of Medical Uncertainty. *Acad. Med.*, 2021, vol. 96, no. 1, pp. 31–36.
4. Reva S. A., Shaderkin I. A., Ziatchin I. V., Petrov S. B. Artificial intelligence in oncurology. *Eksperimental'naiia i klinicheskaia urologiia*, 2021, vol. 14, no. 2, pp. 46–51. (In Russian)
5. Wang J., Wu C. J., Bao M. L., Zhang J., Wang X. N., Zhang Y. D. Machine learning-based analysis of MR radiomics can help to improve the diagnostic performance of PI-RADS v2 in clinically relevant prostate cancer. *Eur. Radiol.*, 2017, vol. 27, no. 10, pp. 4082–4090.
6. Alvarez-Jimenez C., Barrera C., Munera N., Viswanath S. E., Romero E. Differentiating Cancerous and Non-cancerous Prostate Tissue Using Multi-scale Texture Analysis on MRI. *Annu. Int. Conf. IEEE Eng. Med. Biol. Soc.*, 2019, pp. 2695–2698.
7. Cuocolo R., Stanzione A., Faletti R., Gatti M., Callaris G., Fornari A., Gentile F., Motta A., Dell'Aversana S., Creta M., Longo N., Gontero P., Cirillo S., Fonio P., Imbriaco M. MRI index lesion radiomics and machine learning for detection of extraprostatic extension of disease: a multicenter study. *Eur. Radiol.*, 2021, vol. 31, no. 10, pp. 7575–7583.
8. Gholizadeh N., Simpson J., Ramadan S., Denham J., Lau P., Siddique S., Dowling J., Welsh J., Chalup S., Greer P. B. Voxel-based supervised machine learning of peripheral zone prostate cancer using noncontrast multiparametric MRI. *J. Appl. Clin. Med. Phys.*, 2020, vol. 21, no. 10, pp. 179–191.
9. Giannini V., Mazzetti S., Defeudis A., Stranieri G., Calandri M., Bollito E., Bosco M., Porpiglia F., Manfredi M., De Pascale A., Veltri A., Russo F., Regge D. A Fully Automatic Artificial Intelligence System Able to Detect and Characterize Prostate Cancer Using Multiparametric MRI: Multicenter and Multi-Scanner Validation. *Front. Oncol.*, 2021, vol. 11, p. 718155.
10. Varghese B., Chen F., Hwang D., Palmer S. L., De Castro Abreu A. L., Ukimura O., Aron M., Aron M., Gill I., Duddalwar V., Pandey G. Objective risk stratification of prostate cancer using machine learning and radiomics applied to multiparametric magnetic resonance images. *Sci. Reports*, 2019, vol. 9, no. 1, pp. 1–10.
11. Kwon D., Reis I. M., Breto A. L., Tschudi Y., Gautney N., Zavala-Romero O., Lopez C., Ford J. C., Punnen S., Pollack A., Stoyanova R. Classification of suspicious lesions on prostate multiparametric MRI using machine learning. *J. Med. Imaging*, 2018, vol. 5, no. 3, p. 034502.
12. Hectors S. J., Chen C., Chen J., Wang J., Gordon S., Yu M., Al Hussein Al Awamlh B., Sabuncu M. R., Margolis D. J. A., Hu J. C. Magnetic Resonance Imaging Radiomics-Based Machine Learning Prediction of Clinically Significant Prostate Cancer in Equivocal PI-RADS 3 Lesions. *J. Magn. Reson. Imaging*. 2021, vol. 54, no. 5, pp. 1466–1473.
13. Zhang L., Zhe X., Tang M., Zhang J., Ren J., Zhang X., Li L. Predicting the Grade of Prostate Cancer Based on a Biparametric MRI Radiomics Signature. *Contrast Media Mol Imaging*, 2021, 7830909.

14. Liu B., Cheng J., Guo D.J., He X.J., Luo Y.D., Zeng Y., Li C.M. Prediction of prostate cancer aggressiveness with a combination of radiomics and machine learning-based analysis of dynamic contrast-enhanced MRI. *Clin. Radiol.*, 2019, vol. 74, no. 11, pp. 896.e1–896.e8.
15. Wu M., Krishna S., Thornhill R. E., Flood T. A., McInnes M. D. F., Schieda N. Transition zone prostate cancer: Logistic regression and machine-learning models of quantitative ADC, shape and texture features are highly accurate for diagnosis. *J. Magn. Reson. Imaging*, 2019, vol. 50, no. 3, pp. 940–950.
16. Iyama Y., Nakaura T., Katahira K., Iyama A., Nagayama Y., Oda S., Utsunomiya D., Yamashita Y. Development and validation of a logistic regression model to distinguish transition zone cancers from benign prostatic hyperplasia on multi-parametric prostate MRI. *Eur. Radiol.*, 2017, vol. 27, no. 9, pp. 3600–3608.
17. Akamine Y., Ueda Y., Ueno Y., Sofue K., Murakami T., Yoneyama M., Obara M., Van Cauteren M. Application of hierarchical clustering to multi-parametric MR in prostate: Differentiation of tumor and normal tissue with high accuracy. *Magn. Reson. Imaging*, 2020, vol. 74, pp. 90–95.
18. Liu S., Zheng H., Feng Y., Li W. Prostate Cancer Diagnosis using Deep Learning with 3D Multiparametric MRI. arXiv:1703.04078.
19. Stanzione A., Cuocolo R., Coccoza S., Romeo V., Persico F., Fusco F., Longo N., Brunetti A., Imbriaco M. Detection of Extraprostatic Extension of Cancer on Biparametric MRI Combining Texture Analysis and Machine Learning: Preliminary Results. *Acad. Radiol.*, 2019, vol. 26, no. 10, pp. 1338–1344.
20. Ishioka J., Matsuoka Y., Uehara S., Yasuda Y., Kijima T., Yoshida S., Yokoyama M., Saito K., Kihara K., Numao N., Kimura T., Kudo K., Kumazawa I., Fujii Y. Computer-aided diagnosis of prostate cancer on magnetic resonance imaging using a convolutional neural network algorithm. *B. J. U. Int.*, 2018, vol. 122, no. 3, pp. 411–417.
21. Zabihollahy F., Ukwatta E., Krishna S., Schieda N. Fully automated localization of prostate peripheral zone tumors on apparent diffusion coefficient map MR images using an ensemble learning method. *J. Magn. Reson. Imaging*, 2020, vol. 51, no. 4, pp. 1223–1234.
22. Mehrtash A., Sedghi A., Ghafoorian M., Taghipour M., Tempany C. M., Wells W. M. 3rd, Kapur T., Mousavi P., Abolmaesumi P., Fedorov A. Classification of Clinical Significance of MRI Prostate Findings Using 3D Convolutional Neural Networks. *Proc. SPIE Int. Soc. Opt. Eng.*, 2017, pp. 10134–10134A.
23. Saha A., Hosseinzadeh M., Huisman H. End-to-end prostate cancer detection in bpMRI via 3D CNNs: Effects of attention mechanisms, clinical priori and decoupled false positive reduction. *Med. Image Anal.*, 2021, vol. 73, p. 102155.
24. Chen Q., Hu S., Long P., Lu F., Shi Y., Li Y. A Transfer Learning Approach for Malignant Prostate Lesion Detection on Multiparametric MRI. *Technol. Cancer Res. Treat.*, 2019, vol. 18, p. 1533033819858363.
25. Sobiecki P., Józwiak R., Sklinda K., Przelaskowski A. Effect of domain knowledge encoding in CNN model architecture—a prostate cancer study using mpMRI images. *PeerJ*, 2021, no. 9, p. e11006.
26. Sanyal J., Banerjee I., Hahn L., Rubin D. An Automated Two-step Pipeline for Aggressive Prostate Lesion Detection from Multi-parametric MR Sequence. *AMIA J. Summits Transl. Sci. Proc.*, 2020, pp. 552–560.
27. Bhattacharya I., Seetharaman A., Shao W., Sood R., Kunder C. A., Fan R. E., Soerensen S. J. C., Wang J. B., Ghanouni P., Teslovich N. C., Brooks J. D., Sonn G. A., Rusu M. CorrSigNet: Learning CORRelated Prostate Cancer SIGnatures from Radiology and Pathology Images for Improved Computer Aided Diagnosis. *Lect. Notes Comput. Sci. (including Subser Lect Notes Artif Intell Lect Notes Bioinformatics)*, 2020, 12262 LNCS, pp. 315–325.
28. Yu X., Lou B., Shi B., Winkel D., Arrahmane N., Diallo M., Meng T., von Busch H., Grimm R., Kiefer B., Comaniciu D., Kamen A., Huisman H., Rosenkrantz A., Penzkofer T., Shabunin I., Yang Q., Szolar D. False Positive Reduction Using Multiscale Contextual Features for Prostate Cancer Detection in Multi-Parametric MRI Scans. *Proc. — Int. Symp. Biomed. Imaging*, 2020, pp. 1355–1359.
29. Yoo S., Gujrathi I., Haider M. A., Khalvati F. Prostate Cancer Detection using Deep Convolutional Neural Networks. *Sci. Reports*, 2019, vol. 9, no. 1, pp. 1–10.
30. Zhong X., Cao R., Shakeri S., Scalzo F., Lee Y., Enzmann D. R., Wu H. H., Raman S. S., Sung K. Deep transfer learning-based prostate cancer classification using 3 Tesla multi-parametric MRI. *Abdom. Radiol.*, 2019, vol. 44, no. 6, pp. 2030–2039.
31. Khosravi P., Lysandrou M., Eljalby M., Li Q., Kazemi E., Zisimopoulos P., Sigaras A., Brendel M., Barnes J., Ricketts C., Meleshko D., Yat A., McClure T. D., Robinson B. D., Sboner A., Elemento O.,

- Chughtai B., Hajirasouliha I. A Deep Learning Approach to Diagnostic Classification of Prostate Cancer Using Pathology-Radiology Fusion. *J. Magn. Reson. Imaging*, 2021, vol. 54, no. 2, pp. 462–471.
32. Arif M., Schoots I. G., Castillo Tovar J., Bangma C. H., Krestin G. P., Roobol M. J., Niessen W., Veerland J. F. Clinically significant prostate cancer detection and segmentation in low-risk patients using a convolutional neural network on multi-parametric MRI. *Eur. Radiol.*, 2020, vol. 30, no. 12, pp. 6582–6592.
 33. Wang Z., Liu C., Cheng D., Wang L., Yang X., Cheng K. T. Automated Detection of Clinically Significant Prostate Cancer in mp-MRI Images Based on an End-to-End Deep Neural Network. *IEEE Trans. Med. Imaging*, 2018, vol. 37, no. 5, pp. 1127–1139.
 34. Abdelmaksoud I. R., Shalaby A., Mahmoud A., Elmogy M., Aboelfetouh A., Abou El-Ghar M., El-Melegy M., Alghamdi N. S., El-Baz A. Precise Identification of Prostate Cancer from DWI Using Transfer Learning. *Sensors (Basel)*, 2021, vol. 21, no. 11, p. 3664.
 35. Aldoj N., Lukas S., Dewey M., Penzkofer T. Semi-automatic classification of prostate cancer on multi-parametric MR imaging using a multi-channel 3D convolutional neural network. *Eur. Radiol.*, 2020, vol. 30, no. 2, pp. 1243–1253.
 36. Song Y., Zhang Y. D., Yan X., Liu H., Zhou M., Hu B., Yang G. Computer-aided diagnosis of prostate cancer using a deep convolutional neural network from multiparametric MRI. *J. Magn. Reson. Imaging*, 2018, vol. 48, no. 6, pp. 1570–1577.
 37. Pellicer-Valero O. J., Marengo Jiménez J. L., Gonzalez-Perez V., Casanova Ramón-Borja J. L., Martín García I., Barrios Benito M., Pelechano Gómez P., Rubio-Briones J., Rupérez M. J., Martín-Guerrero J. D. Deep learning for fully automatic detection, segmentation, and Gleason grade estimation of prostate cancer in multiparametric magnetic resonance images. *Sci. Rep.*, 2022, vol. 12, no. 1, p. 2975.
 38. Xu H., Baxter J. S. H., Akin O., Cantor-Rivera D. Prostate cancer detection using residual networks. *Int. J. Comput. Assist. Radiol. Surg.*, 2019, vol. 14, no. 10, pp. 1647–1650.
 39. Brunese L., Mercaldo F., Reginelli A., Santone A. Radiomics for Gleason Score Detection through Deep Learning. *Sensors (Basel)*, 2020, vol. 20, no. 18, p. 5411.
 40. Cao R., Mohammadian Bajgiran A., Afshari Mirak S., Shakeri S., Zhong X., Enzmann D., Raman S., Sung K. Joint Prostate Cancer Detection and Gleason Score Prediction in mp-MRI via FocalNet. *IEEE Trans. Med. Imaging*, 2019, vol. 38, no. 11, pp. 2496–2506.
 41. Hou Y., Zhang Y. H., Bao J., Yang G., Shi H.-B., Song Y., Yu-Dong Zhang Y.-D. Artificial intelligence is a promising prospect for the detection of prostate cancer extracapsular extension with mpMRI: a two-center comparative study. *Eur. J. Nucl. Med. Mol. Imaging*, 2021, vol. 48, no. 12, pp. 3805–3816.
 42. Zong W., Lee J. K., Liu C., Carver E. N., Feldman A. M., Janic B., Elshaiikh M. A., Pantelic M. V., Hearshen D., Chetty I. J., Movsas B., Wen N. A Deep Dive into Understanding Tumor Foci Classification using Multiparametric MRI Based on Convolutional Neural Network. *Med. Phys.*, 2019, vol. 47, no. 9, pp. 4077–4086.
 43. Somov A. N., Suslin S. A. Prostate cancer. Epidemiology, risk factors and early detection. *Profilakticheskaya meditsina*, 2020, vol. 23, no. 3, pp. 149–155. (In Russian)
 44. Schelb P., Kohl S., Radtke J. P., Wiesenfarth M., Kickingereeder P., Bickelhaupt S., Kuder T. A., Stenzinger A., Hohenfellner M., Schlemmer H. P., Maier-Hein K. H., Bonekamp D. Classification of Cancer at Prostate MRI: Deep Learning versus Clinical PI-RADS Assessment. *Radiology*, 2019, vol. 293, no. 3, pp. 607–617.
 45. Youn S. Y., Choi M. H., Kim D. H., Lee Y. J., Huisman H., Johnson E., Penzkofer T., Shabunin I., Winkel D. J., Xing P., Szolar D., Grimm R., von Busch H., Son Y., Lou B., Kamen A. Detection and PI-RADS classification of focal lesions in prostate MRI: Performance comparison between a deep learning-based algorithm (DLA) and radiologists with various levels of experience. *Eur. J. Radiol.*, 2021, vol. 142, p. 109894.
 46. Sanford T., Harmon S. A., Turkbey E. B., Kesani D., Tuncer S., Madariaga M., Yang C., Sackett J., Mehralivand S., Yan P., Xu S., Wood B. J., Merino M. J., Pinto P. A., Choyke P. L., Turkbey B. Deep-Learning-Based Artificial Intelligence for PI-RADS Classification to Assist Multiparametric Prostate MRI Interpretation: A Development Study. *J. Magn. Reson. Imaging*, 2020, vol. 52, no. 5, pp. 1499–1507.
 47. Le M. H., Chen J., Wang L., Wang Z., Liu W., Cheng K. T., Yang X. Automated diagnosis of prostate cancer in multi-parametric MRI based on multimodal convolutional neural networks. *Phys. Med. Biol.*, 2017, vol. 62, no. 16, pp. 6497–6514.

48. Hao R., Namdar K., Liu L., Haider M. A., Khalvati F. A Comprehensive Study of Data Augmentation Strategies for Prostate Cancer Detection in Diffusion-weighted MRI using Convolutional Neural Networks. *J. Digit. Imaging*, 2020, vol. 34, no. 4, pp. 862–876.
49. Castillo T. J. M., Arif M., Starmans M. P. A., Niessen W. J., Bangma C. H., Schoots I. G., Veenland J. F. Classification of Clinically Significant Prostate Cancer on Multi-Parametric MRI: A Validation Study Comparing Deep Learning and Radiomics. *Cancers (Basel)*, 2021, vol. 14, no. 1, p. 12.
50. Bonekamp D., Kohl S., Wiesenfarth M., Schelb P., Radtke J. P., Götz M., Kickingereeder P., Yaqubi K., Hitthaler B., Gähler N., Kuder T. A., Deister F., Freitag M., Hohenfellner M., Hadaschik B. A., Schlemmer H. P., Maier-Hein K. H. Radiomic machine learning for characterization of prostate lesions with MRI: Comparison to ADC values. *Radiology*, 2018, vol. 289, no. 1, pp. 128–137.
51. Meyer H. J., Wienke A., Surov A. Discrimination between clinical significant and insignificant prostate cancer with apparent diffusion coefficient — a systematic review and meta analysis. *BMC Cancer*, 2020, vol. 20, no. 1, p. 482.
52. Algohary A., Shiradkar R., Pahwa S., Puryško A., Verma S., Moses D., Shnier R., Haynes A. M., Delprado W., Thompson J., Tirumani S., Mahran A., Rastinehad A. R., Ponsky L., Stricker P. D., Madabhushi A. Combination of Peri-Tumoral and Intra-Tumoral Radiomic Features on Bi-Parametric MRI Accurately Stratifies Prostate Cancer Risk: A Multi-Site Study. *Cancers (Basel)*, 2020, vol. 12, no. 8, p. 2200.

Статья поступила в редакцию 28 марта 2023 г.;
рекомендована к печати 28 мая 2023 г.

Контактная информация:

Тальшинский Али Эльманович — аспирант, ассистент; ali-ma@mail.ru

Камышанская Ирина Григорьевна — д-р мед. наук, доц.; irinaka@mail.ru

Мищенко Андрей Владимирович — д-р мед. наук, проф.; dr.mishchenko@mail.ru

Гулиев Бахман Гидаятович — д-р мед. наук, проф.; gulievb@mail.ru

Бахтиозин Рустам Фаридович — д-р мед. наук, проф.; rbakhtiozin@yahoo.com

Application of artificial intelligence in the detection and stratification of prostate cancer: Literature review

A. E. Talyshinskii^{1,2}, *I. G. Kamyshanskaya*^{2,3}, *A. V. Mischenko*^{2,4,5},
*B. G. Guliev*³, *R. F. Bakhtiozin*⁶

¹ Astana Medical University,
49a, ul. Beibitshilik, Astana, 010000, Kazakhstan

² St. Petersburg State University,
7–9, Universitetskaya nab., St. Petersburg, 199034, Russian Federation

³ St. Petersburg City Mariinsky Hospital,
56, Liteiny pr., St. Petersburg, 191014, Russian Federation

⁴ Russian Medical Academy of Continuous Professional Education,
2/1, ul. Barrikadnaya, Moscow, 125993, Russian Federation

⁵ National Medical Research Center of Oncology named after N. N. Petrov,
68, Leningradskaya ul., St. Petersburg, 197758, Russian Federation

⁶ I. M. Sechenov First Moscow State Medical University (Sechenov University),
8, ul. Trubetskaya, Moscow, 119048, Russian Federation

For citation: Talyshinskii A. E., Kamyshanskaya I. G., Mischenko A. V., Guliev B. G., Bakhtiozin R. F. Application of artificial intelligence in the detection and stratification of prostate cancer: Literature review. *Vestnik of Saint Petersburg University. Medicine*, 2023, vol. 18, issue 2, pp. 150–166. <https://doi.org/10.21638/spbu11.2023.204> (In Russian)

This review examines the current methodologies employed in utilizing artificial intelligence for the identification and classification of prostate cancer using magnetic resonance imaging

data. It outlines the volume of data utilized and highlights the most commonly sought-after sequences employed for training neural networks. The review further presents the accuracy metrics of the neural networks analyzed, accompanied by a succinct explanation of each metric. Furthermore, the review pinpoints the limitations associated with contemporary neural networks devised for the detection and classification of prostate cancer using magnetic resonance imaging data, as well as the challenges encountered during their creation and implementation. In summary, this comprehensive analysis delves into the existing approaches in leveraging artificial intelligence for prostate cancer detection and stratification through magnetic resonance imaging data. It addresses the data scale and preferred magnetic resonance imaging sequences employed for neural network training. The review provides a breakdown of accuracy indicators for the neural networks evaluated, elucidating their respective capabilities. Moreover, the review identifies the drawbacks associated with current neural network models developed for prostate cancer detection and stratification via magnetic resonance imaging data, while also recognizing the complexities involved in their development and practical application.

Keywords: prostate cancer, MRI, artificial intelligence.

Received: March 28, 2023

Accepted: May 28, 2023

Authors' information:

Ali E. Talyshinskii — Postgraduate Student, Assistant; ali-ma@mail.ru

Irina G. Kamyshanskaya — Dr. Sci. in Medicine, Associate Professor; irinaka@mail.ru

Andrey V. Mishchenko — Dr. Sci. in Medicine, Professor; dr.mishchenko@mail.ru

Bakhman G. Guliev — Dr. Sci. in Medicine, Professor; gulievb@yandex.ru

Rustam F. Bakhtiozin — Dr. Sci. in Medicine, Professor; rbakhtiozin@yahoo.com