

АНАЛИЗ ДАННЫХ ТРУЗИ С ИСПОЛЬЗОВАНИЕМ КОМПЬЮТЕРНОГО ЗРЕНИЯ В ДИАГНОСТИКЕ РАКА ПРЕДСТАТЕЛЬНОЙ ЖЕЛЕЗЫ

*Лумпов И.С.¹, Амосов А.В.¹, Люткин Д.А.², Заев Р.И.³, Романов А.Ю.⁴, Соловьев Р.А.⁵, Сергеев Ю.С.⁶, Амосов Н.А.⁷

3.1.6 - Онкология, лучевая терапия
(медицинские науки)
3.1.25 - Лучевая диагностика
(медицинские науки)

¹ФГАОУ ВО Первый МГМУ им. И. М. Сеченова МЗ РФ (Сеченовский Университет)

²ПАО «Сбербанк»

³АО «Северсталь-инфоком»

⁴Национальный исследовательский университет «Высшая школа экономики»

⁵ООО «АльфаЧип»

⁶ГКБ имени С.С. Юдина

Онкологический центр-1

⁷ГБУЗ МО «МОНИКИ им. М.Ф. Владимирского»

КЛЮЧЕВЫЕ СЛОВА:

- рак простаты
- диагностика
- ТРУЗИ
- компьютерное зрение
- нейросеть
- машинное обучение

АННОТАЦИЯ:

Введение: в данной статье исследуется использование методов машинного обучения для анализа изображений ТРУЗИ простаты с целью автоматизации диагностики рака простаты и повышения точности его выявления. Рак простаты является одним из наиболее распространенных онкологических заболеваний у мужчин. Трансректальное ультразвуковое исследование (ТРУЗИ) играет важную роль в его диагностике, но требует опытного врача для интерпретации результатов.

Цель: исследовать применение методов машинного обучения для автоматизации анализа изображений ТРУЗИ простаты с целью повышения точности диагностики.

Материал и методы: использовались данные ТРУЗИ простаты с верифицированным раком предстательной железы. Изображения обрабатывались методами компьютерного зрения для извлечения признаков, а затем применялись различные алгоритмы машинного обучения, включая нейронные сети и методы семантической сегментации.

Результаты: эксперименты показали, что предложенный подход обеспечивает достаточно высокую точность при диагностике рака простаты на основе изображений ТРУЗИ. Модели машинного обучения способны автоматически выявлять характерные признаки раковых изменений, что может значительно улучшить точность диагностики.

Выводы: результаты исследования подтверждают потенциал методов машинного обучения в анализе изображений ТРУЗИ простаты. Автоматизация этого процесса помогает улучшить эффективность диагностики и сократить время, затрачиваемое на анализ изображений врачами, что в конечном итоге может привести к более успешному лечению и улучшению качества жизни пациентов.

Для цитирования. Лумпов И.С., Амосов А.В., Люткин Д.А., Заев Р.И., Романов А.Ю., Соловьев Р.А., Сергеев Ю.С., Амосов Н.А. «АНАЛИЗ ДАННЫХ ТРУЗИ С ИСПОЛЬЗОВАНИЕМ КОМПЬЮТЕРНОГО ЗРЕНИЯ В ДИАГНОСТИКЕ РАКА ПРЕДСТАТЕЛЬНОЙ ЖЕЛЕЗЫ». Ж. ДИАГНОСТИЧЕСКАЯ И ИНТЕРВЕНЦИОННАЯ РАДИОЛОГИЯ. 2024; 18(2.1): 87–93.

TRANSRECTAL ULTRASOUND DATA ANALYSIS WITH COMPUTER VISION IN PROSTATE CANCER DIAGNOSTICS

*Lumpov I.S.¹, Amosov A.V.¹, Lyutkin D.A.², Zaev R.I.³, Romanov A.Yu.⁴, Solovyov R.A.⁵, Sergeev Yu.S.⁶, Amosov N.A.⁷

¹Federal State Autonomous Educational Institution of Higher Education I.M. Sechenov First Moscow State Medical University of the Ministry of Health of the Russian Federation (Sechenov University)

²Sberbank

³Severstal-Infocom

⁴HSE University

⁵AlphaChip

⁶City Clinical Hospital S.S. Yudin

Oncology centre-1

⁷Moscow Regional Scientific Research Clinical Institute n.a. M.F. Vladimirskiy

KEY-WORDS:

- prostate cancer
- diagnostic
- TRUS
- computer vision
- neural network
- machine learning

ABSTRACT:

Introduction: this article describes the use of machine learning methods for analyzing prostate tissue images in order to automate the diagnosis of prostate cancer and improve the accuracy of its detection. Prostate cancer is one of the most common conditions in men. Transrectal ultrasound (TRUS) plays an important role in its diagnosis but requires an experienced physician to interpret the results.

Aim: was to study the application of machine learning methods to automate the analysis of prostate tissue images so as to improve the accuracy of diagnosis.

Material and methods: we used the data of prostate examination with verified prostate cancer. The images were processed using computer vision techniques to extract signs. After that various machine learning algorithms were applied, including neural networks and semantic segmentation methods.

Results: experiments have shown that the proposed approach provides high diagnostic accuracy for prostate cancer based on TRUS images. Machine learning models are able to automatically identify the pathognomy of cancerous changes and can greatly improve the diagnostic precision.

Conclusions: results of the study confirm the potential of machine learning methods in the analysis of prostate tissue images. Automating this process raises diagnostic efficiency and reduces the time spent on image analysis by doctors. Finally, it leads to successful treatment and improved quality of life for patients.

Введение

Заболеваемость раком по всему миру неуклонно растет. Например, в 2020 году было отмечено приблизительно 19,3 миллиона новых случаев [1,2]. Рак предстательной железы (РПЖ) встречается у примерно шести из десяти мужчин старше 65 лет. Данное заболевание чаще выявляется среди мужчин Карибского региона (Колумбия, Куба, Гаити и пр.) и афроамериканцев, чем среди представителей других этнических групп, но причина этого явления остается неясной. Из-за высокой распространенности РПЖ является вторым по частоте диагностирования среди раков солидных органов у мужчин после рака легких [3]. В 2021 году Американское общество по борьбе с раком оценило, что только в Соединенных Штатах у около 250 тысяч мужчин был выявлен рак предстательной железы. При этом порядка 34 тысяч из них умерли от этого заболевания [4]. Эти цифры подчеркивают, что РПЖ занимает одно из первых мест по распространенности так же среди причин смерти от рака у мужчин [5,6]. Основными факторами риска являются возраст, наличие онкологических заболеваний в семейном анамнезе, а также раса [7,8]. Несмотря на то, что данное заболевание чаще всего встречается у мужчин среднего возраста, оно может затронуть любого. Современная медицина научилась успешно бороться с раком предстательной железы. Раннее обнаружение этого заболевания играет решающую роль в успешном лечении. При обнаружении РПЖ на ранней стадии, десятилетняя выживаемость у мужчин с локализованным раком предстательной железы составляет до 99% [9]. Болезнь часто развивается медленно,

и на ранних стадиях, как правило, протекает бессимптомно [10]. Регулярное обследование предстательной железы, особенно у мужчин старше 50 лет или у пациентов с отягощенным семейным анамнезом, помогает обнаружить рак на ранней стадии, когда лечение наиболее эффективно. Скрининг на рак предстательной железы включает в себя пальцевое ректальное исследование, трансректальное ультразвуковое исследование (ТРУЗИ) и анализ крови на уровень простат-специфического антигена (ПСА) [11].

Несмотря на то, что раннее выявление заболевания имеет важное значение, исследования рака предстательной железы остаются трудоемкими. Сложность заболевания и разнообразие его субтипов требуют многостороннего подхода к исследованиям и лечению. Генетические исследования являются одной из областей внимания, но не менее важным являются исследования новых технологий обработки изображений, полученных при диагностике рака предстательной железы. Интерпретация изображений предстательной железы, полученных с помощью ТРУЗИ, может быть осложнена и зависит от опыта врача. В последние годы методы машинного обучения, такие как нейронные сети и алгоритмы классификации, предоставляют новые возможности для автоматизации и улучшения процесса анализа диагностических изображений. Внедрение компьютерного зрения в процесс диагностики рака простаты может значительно повысить точность и скорость обнаружения заболевания, что в свою очередь позволяет улучшить прогнозирование и результаты лечения. Такие

инновации являются важным шагом в борьбе с этим серьезным заболеванием, способствуя сохранению здоровья мужчин и снижению смертности от рака простаты [12].

Компьютерное зрение реализуется с помощью искусственной нейронной сети, анализирующей изображения. В частности, одним из видов таких нейронных сетей являются сверточные сети [13], в последние годы они получили свое распространение как один из основных инструментов компьютерного зрения. Эти сети позволяют анализировать данные, определять общие черты в изображениях и выделять наиболее важные элементы. Использование сверточных нейронных сетей особенно эффективно при обнаружении РПЖ с использованием изображений ТРУЗИ, даже при их низком качестве. Поскольку изображения ТРУЗИ содержат много шума и области низкого качества, необходимы использовать предварительные техники обработки, такие как нормализация, масштабирование и увеличение выборки. Кроме того, для достижения высокой точности в долгосрочной перспективе необходимы репрезентативные данные для обучения [14]. Большое количество современных работ по теме рака простаты посвящены диагностике на основе данных МРТ. В одной из таких работ [15] представлены результаты исследования эффективности глубокого обучения на примере обнаружения клинически значимого рака предстательной железы. Исследователи использовали два набора данных: общедоступный Cancer AI (PI-CAI) и собственные многоцентровые данные. С помощью модели nnU-Net, обученной на данных PI-CAI, они достигли высокой производительности в обнаружении рака предстательной железы, как на внешних, так и внутренних тестовых наборах данных. Использование вероятностных масок предстательной железы в этой модели позволило добиться точного обнаружения рака при дальнейшей передаче обучения на другие наборы данных. Такой подход обеспечивает надежность и обобщаемость глубокого обучения в различных контекстах, что подчеркивает его потенциал для улучшения диагностики рака предстательной железы в клинической практике.

В отличие от МРТ, которая имеет свои противопоказания, ТРУЗИ обычно является безопасной процедурой с наименьшим количеством противопоказаний, что делает его более доступным для широкого круга пациентов. К таковым относятся пациенты с металлическими имплантатами или пациенты, испытывающие дискомфорт в замкнутых пространствах. Кроме того, ТРУЗИ зачастую более доступно и обычно стоит дешевле, чем МРТ. Это особенно важно для пациентов с ограниченными финансовыми возможностями или в регионах, где доступ к МРТ ограничен.

Таким образом, ТРУЗИ имеет не только меньше противопоказаний и является экономически более доступным методом

диагностики, но и обеспечивает ряд преимуществ, что делает его важным инструментом в диагностике рака предстательной железы.

Целью данной работы является исследование применения методов машинного обучения для анализа изображений ТРУЗИ простаты с целью улучшения точности диагностики рака простаты и автоматизации его выявления.

Материал и методы

В данном исследовании мы используем датасет, основанный на снимках трансректального ультразвукового исследования (ТРУЗИ) пациентов с подтвержденным диагнозом рака предстательной железы. Процесс получения снимков состоит из выполнения трансректального ультразвукового исследования (рис. 1) и выявления патологического очага с опорой на визуальный контроль и предварительно выполненное магнитно-резонансное томографическое (МРТ) исследование предстательной железы. Затем, путем трассировки, выполняется локализация пораженного участка предстательной железы (рис. 2). На основании полученных снимков при помощи программного обеспечения RoboFlow [16] выполняется построение маски для последующего обучения нейронной сети.

Сегментация раковых опухолей на изображениях ТРУЗИ играет важную роль в медицинской практике, способствуя раннему выявлению и мониторингу онкологических заболеваний предстательной железы. Для решения этой задачи широко применяются методы глубокого обучения, включая разнообразные архитектуры нейронных сетей. Одной из таких архитектур, демонстрирующей высокую эффективность в сегментационных задачах, является Unet++.

Unet++ [17] является модификацией известной архитектуры Unet, разработанной Ольгердом Шегевицем (Olaf Ronneberger) и его коллегами в 2015 году. Она расширяет оригинальную архитектуру Unet, добавляя дополнительные пути как в кодировщик, так и в декодировщик сети, что делает ее более глубокой и мощной.

Основные преимущества архитектуры Unet++ включают:

- Множество путей: Unet++ использует несколько путей, связывающих кодировщик и декодировщик сети, что позволяет более эффективно передавать контекстную информацию между слоями и учитывать различные масштабы объектов на изображении.
- Гибкость и модульность: Unet++ легко расширяема и модульна, что обеспечивает простоту внедрения различных модификаций и адаптацию архитектуры под конкретную задачу сегментации. Модульность также упрощает настройку и оптимизацию сети.
- Использование skip-connections: Unet++ использует про-




Рис. 1. Снимок ТРУЗИ предстательной железы с выделенным участком поражения ткани.



Рис. 2. Изображение ТРУЗИ с нанесенной разметкой.

пускающие соединения, позволяющие объединять информацию с разных уровней разрешения изображения, что способствует более точной локализации и сегментации опухолей.

- Реализация архитектуры Unet++ для сегментации раковых опухолей на изображениях ТРУЗИ может быть осуществлена с использованием популярной библиотеки глубокого обучения Segmentation Models для фреймворка PyTorch. Эта библиотека предоставляет готовые реализации множества архитектур сегментации, включая Unet++, что упрощает процесс разработки.

Процесс автоматического выделения различных структур и областей на изображениях ТРУЗИ в области трансректального ультразвукового исследования для диагностики РПЖ представляет собой семантическую сегментацию, которая облегчает диагностику и лечение данного заболевания. Для этого применяются различные методы семантической сегментации. Методы на основе глубокого обучения, такие как U-Net, SegNet, Mask R-CNN и другие, широко используются для точного выделения областей предстательной железы, опухолей или других аномалий на изображениях ТРУЗИ. Эти методы тренируются на обширных наборах данных, что позволяет им достигать высокой точности. Некоторые методы семантической сегментации используют анализ текстурных и структурных признаков на изображениях ТРУЗИ для выделения интересующих областей. Это включает применение методов компьютерного зрения, таких как фильтры Габора [18] или текстурный анализ, для определения границ и характеристик тканей. В некоторых случаях для повышения точности сегментации применяются методы активного обучения, которые позволяют системе запросить у пользователя информацию о правильной маркировке некоторых областей на изображениях. Это помогает модели улучшить свою точность, особен-

но при наличии недостаточного или неоднородного обучающего набора данных. Интеграция с другими модальностями, такими как МРТ или ПЭТКТ, также может использоваться для улучшения точности диагностики. Это позволяет использовать мультимодальные алгоритмы сегментации или совместную интерпретацию данных из различных источников. Эти методы семантической сегментации играют важную роль в повышении точности и эффективности диагностики рака предстательной железы на изображениях ТРУЗИ, что способствует более точному выявлению опухолей и оценке их степени распространения.

Результаты

Были исследованы параметры модели Unet++, применяемой для решения задачи сегментации раковых опухолей на изображениях трансректального ультразвукового исследования (ТРУЗИ) с использованием библиотеки Segmentation Models PyTorch.

В результате чего были выбраны следующие параметры модели: encoder_name - «resnet_152», encoder_weights - «imagenet», activation - «sigmoid», in_channels - 3, classes - 1. Выбор данных параметров модели определяется спецификой поставленной задачи, включая сложность модели, использование предварительных обученных весов, функцию активации, количество входных каналов и количество классов для предсказания. Эти параметры были выбраны на основе анализа данных и задачи, а также предыдущего опыта. Учитывая выбранные параметры модели, процесс реализации алгоритма обучения включает в себя подготовку данных, создание модели с учетом указанных параметров, определение функции потерь, выбор оптимизатора и гиперпараметров, а также обучение модели на тренировочном наборе данных (рис. 3).

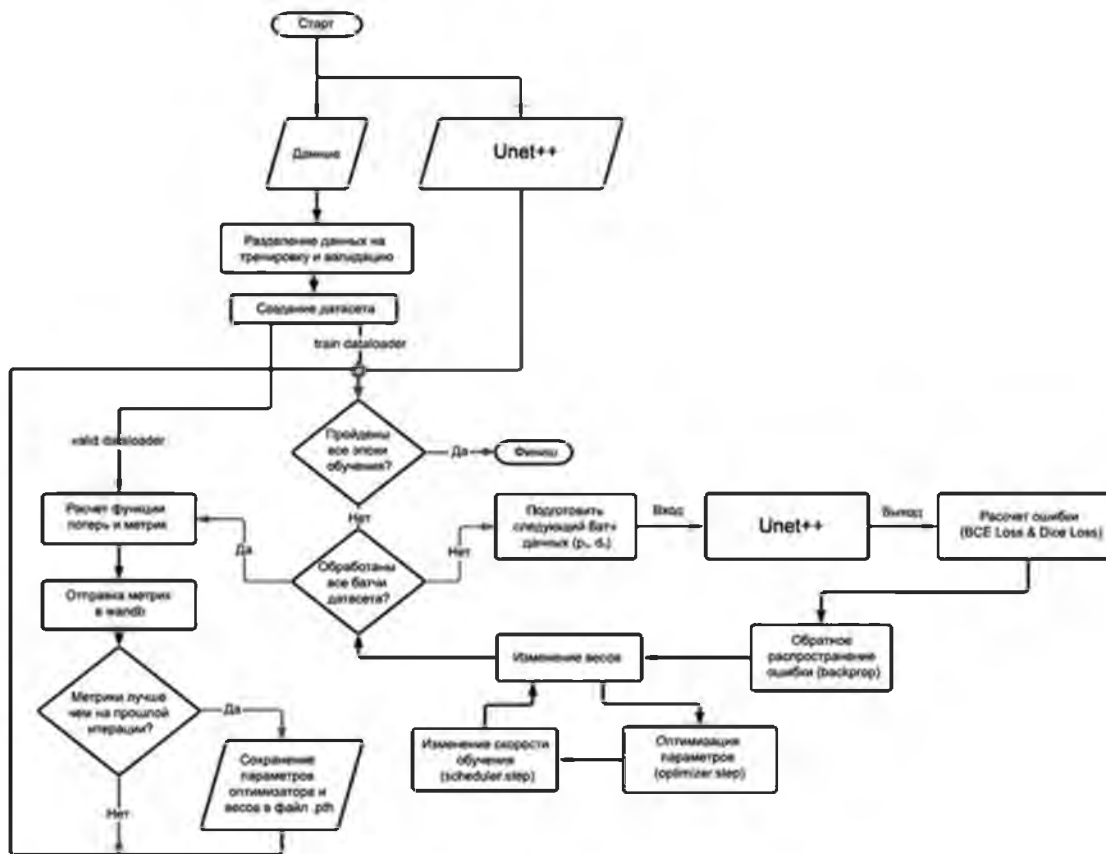


Рис. 3. Архитектура алгоритма обучения [19].

Затем модель подлежит оценке на валидационном наборе данных и, при необходимости, дополнительной настройке. После завершения этих этапов модель готова к использованию для сегментации раковых опухолей на новых изображениях и оценке ее производительности. Эксперименты показали, что предложенный подход позволяет добиться высокой точности при диагностике рака простаты на основе изображений ТРУЗИ. Модели машинного обучения продемонстрировали способность к автоматическому выявлению характерных признаков раковых изменений, что может помочь врачам в принятии более точных решений.

В рамках исследования алгоритм машинного обучения был обучен с учетом двух критериев оценки: оценки во время обучения нейронной сети и оценки результата ее прогнозов. Для обучения нейронной сети была выбрана комбинация двух функций расчета ошибок - DiceLoss и BCELoss. DiceLoss обеспечивает более сбалансированную меру сходства между предсказанными и истинными масками, в то время как BCELoss измеряет разницу между предсказанной вероятностью положительного класса и фактической меткой.

Оценка точности и эффективности нейросетевой модели сегментации является ключевым этапом в ее тестировании. Для этой цели часто применяются две метрики: Intersection over Union (IoU) [20] и коэффициент сходства Dice (DSC) [21]. IoU измеряет степень перекрытия между предсказанной и истинной масками сегментации, оценивая качество сегментации объектов на изображении. DSC также оценивает сходство двух наборов масок сегментации и часто используется для оценки эффективности моделей, особенно в медицинских изображениях. Кроме того, важно визуально проверить результаты сегментации для выявления возможных ошибок или неправильных классификаций.

Оценка производительности нейросетевой модели сегментации может производиться путем комбинации количественных показателей и визуального анализа результатов. В исследо-

вании был применен алгоритм оптимизации Adam W, который, в отличие от RMSprop, обладает большей устойчивостью к шумным градиентам. Оптимальная скорость обучения для данного алгоритма зависит от конкретной задачи и обычно определяется экспериментально. Для улучшения процесса обучения был выбран линейный планировщик с разминкой, который позволяет постепенно увеличивать скорость обучения на начальных этапах.

В процессе обучения применялся особый метод дополнения изображений: каждый снимок случайным образом подвергался изменениям с определенной вероятностью. Это позволило нейронной сети видеть различные данные при каждом входе. Параметры алгоритма сохранялись при улучшении результатов, и, если качество не улучшалось в течение заданного числа попыток, обучение прекращалось. Такой подход помог модели не только обучаться на имеющихся данных, но и сохранить ее способность к обобщению при поступлении новых входных данных. Для повышения стабильности обучения и улучшения способности модели к обобщению был использован планировщик ReduceLRonPlateau. Он автоматически уменьшает скорость обучения, если качество модели на валидационном наборе данных не улучшается. Это предотвращает попадание в локальные минимумы и перескакивание через глобальные минимумы функции потерь. Кроме того, были внесены изменения в исходные коды библиотеки Segmentation Models PyTorch для добавления нормализации градиентов на каждом батче. Это улучшило стабильность и скорость обучения модели, а также ее способность к обобщению. Модель нейронной сети обучалась в три этапа. Сначала данные были разделены на три группы с использованием метода KFold из библиотеки scikit-learn. Затем модель обучалась на каждой из этих групп, а для проверки ее производительности использовались данные, которые не использовались в процессе обучения (валидационные данные). При обучении на тренировочных данных и валидации на 30% из них, значения коэффициента пересечения (IoU) находились в диапазоне от 0,1 до 0,5, а среднее значение составило 0,46. В то же время тестирование на 20% общего набора данных показало качество 0,3 (рис. 4).

В процессе разработки нейросетевых моделей сегментации валидационный контроль является ключевым этапом. Один из часто используемых методов валидации - это визуальная проверка точности сегментации путем отображения сегментированных областей на изображениях. Этот процесс включает сравнение исходного изображения с результатом сегментации, полученным моделью, чтобы убедиться, что границы сегментированных объектов соответствуют истинным границам объектов на изображении (рис. 5). При проведении проверки модели используется набор тестовых изображений для оцен-




Рис. 4. Качество IoU на валидационных данных.




Рис. 5. Пример предсказания нейросети.



ки ее эффективности. Модель обучается на одном наборе изображений и затем оценивается на тестовом наборе, чтобы определить, способна ли она создавать точные сегментации и обобщать результаты на новых данных. Визуальный контроль результатов сегментации на тестовых изображениях позволяет выявить возможные ошибки или неточности в процессе сегментации и внести соответствующие коррективы в модель. Верификация через визуализацию сегментированных областей на изображениях обеспечивает быстрый и интуитивно понятный метод оценки качества модели и часто применяется вместе с другими методами проверки, такими как расчет метрик, например, IoU или Dice. Этот этап играет важную роль в обеспечении точности и надежности моделей сегментации в приложениях компьютерного зрения.

Также важно испытывать модель сегментации не только на валидационном наборе данных, но и на новых данных. Если модель слишком хорошо справляется с валидационными данными, она может показывать плохие результаты на новых, неизвестных данных. Поэтому проверка модели на новых данных, которые не использовались во время обучения или проверки, является необходимой для обеспечения ее надежности и способности к обобщению. Тестирование на новых

данных помогает выявить проблемы, такие как смещение набора данных или проблемы обобщения модели, которые могут оставаться незамеченными во время обучения или проверки. Кроме того, тестирование на новых данных позволяет получить более точную оценку эффективности модели и подтвердить ее надежность. Поэтому дальнейшим развитием работы будет дополнение и расширение датасета, что позволит повысить точность и модели.

Выводы

Результаты исследования подтверждают потенциал методов машинного обучения в области анализа изображений ТРУЗИ простаты. Автоматизация этого процесса позволяет значительно улучшить эффективность диагностики рака простаты и сократить время, затрачиваемое на анализ изображений врачами. Также данный метод имеет значительные перспективы для использования при проведении прицельной трансректальной биопсии предстательной железы. Дальнейшее исследование и разработка таких методов оказывает значительное влияние на сферу здравоохранения и улучшение качества жизни пациентов. ■

Список литературы/References

- Gandaglia G, et al. Epidemiology and Prevention of Prostate Cancer. *Eur Urol Oncol. Elsevier.* 2021; 4(6): 877-892.
- Sung H, et al. Global Cancer Statistics 2020: GLOBOCAN Estimates of Incidence and Mortality Worldwide for 36 Cancers in 185 Countries. *CA Cancer J Clin. Wiley.* 2021; 71(3): 209-249.
- Rawla P. Epidemiology of Prostate Cancer. *World J. Oncol.* 2019; 10: 63-89.
- Chandrasekar T, et al. Collaborative Review: Factors Influencing Treatment Decisions for Patients with a Localized Solid Renal Mass [Formula presented]. *Eur. Urol. Elsevier.* 2021; 80(5): 575-588.
- Rebello RJ, et al. Prostate cancer. *Nat. Rev. Dis. Primers.* 2021; 7: 9.
- Moore BA, Barnett JE. Early Detection of Prostate Cancer: The European Randomized Study of Screening for Prostate Cancer (ERSPC). *Case Studies in Clinical Psychological Science: Bridging the Gap from Science to Practice.* 2021; 1-7.
- 50 Studies Every Urologist Should Know. Oxford University Press. 2021.
- Yang H, et al. Impact of treatment on elder-relevant physical function and quality of life outcomes in older adults with metastatic castration-resistant prostate cancer. *J. Geriatr. Oncol. Elsevier.* 2023; 14(1): 101395.
- Parthipan M, et al. Symptom experiences of older adults during treatment for metastatic prostate cancer: A qualitative investigation. *J. Geriatr. Oncol. Elsevier.* 2023; 14(1): 101397.
- Kim VS, et al. The role of frailty in modifying physical function and quality of life over time in older men with metastatic castration-resistant prostate cancer. *J. Geriatr. Oncol. Elsevier.* 2023; 14(2): 101417.
- Bilal M, et al. An overview of prostate cancer (PCa) diagnosis: Potential role of miRNAs. *Transl Oncol. Elsevier.* 2022; 26: 101542.
- Davies ER. Vision, the challenge. *Computer Vision. Academic Press.* 2018; 1-15.
- Wang Z, et al. A two-stage CNN method for MRI image segmentation of prostate with lesion. *Biomed Signal Process Control. Elsevier.* 2023; 82: 104610.
- Li H, et al. Research on Overfitting of Deep Learning. Proceedings - 2019 15th International Conference on Computational Intelligence and Security, CIS 2019. *IEEE.* 2019; 78-81.
- Karagoz A, et al. Anatomically guided self-adapting deep neural network for clinically significant prostate cancer detection on bi-parametric MRI: a multi-center study. *Insights Imaging. Springer Verlag.* 2023; 14: 110.
- Zaev R, Romanov A, Solovyev R. Segmentation of Prostate Cancer on TRUS Images Using ML. 2023 International Russian Smart Industry Conference (SmartIndustryCon). *IEEE.* 2023; 460-465.
- Zhou Z, et al. UNet++: A Nested U-Net Architecture for Medical Image Segmentation // Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics). *Springer Verlag.* 2018; 11045: 3-11.
- Luan S, et al. Gabor Convolutional Networks. *IEEE Transactions on Image Processing. IEEE.* 2018; 27(9): 4357-4366.
- Ljutkin D, Romanov A, Nasonov D. Segmenting Prostate Cancer on TRUS Images with a Small Dataset: A Comprehensive Methodology. 2023 International Russian Smart Industry Conference (SmartIndustryCon). *IEEE.* 2023; 454-459.
- Rahman MA, Wang, Y. Optimizing Intersection-Over-Union in Deep Neural Networks for Image Segmentation. *Advances in Visual Computing. ISVC 2016. Lecture Notes in Computer Science. Springer.* 2016; 10072.
- D'Aviero A, et al. Clinical Validation of a Deep-Learning Segmentation Software in Head and Neck: An Early Analysis in a Developing Radiation Oncology Center. *Int. J. Environ. Res. Public Health. MDPI.* 2022; 19: 9057.

ИНФОРМАЦИЯ ОБ АВТОРАХ:

- ЛУМПОВ ИЛЬЯ СЕРГЕЕВИЧ** - [ORCID: 0009-0005-6531-2130]
 врач-уролог, врач-УЗД,
 ФГАОУ ВО Первый МГМУ имени И.М. Сеченова МЗ РФ
 (Сеченовский Университет),
 119048 Российская Федерация, г. Москва, ул. Трубецкая, 8 стр. 2;
- АМОСОВ АЛЕКСАНДР ВАЛЕНТИНОВИЧ** - [ORCID: 0000-0003-1374-3367]
 профессор института урологии и репродуктивного здоровья человека,
 ФГАОУ ВО Первый МГМУ имени И.М. Сеченова МЗ РФ
 (Сеченовский Университет),
 119048 Российская Федерация, г. Москва, ул. Трубецкая, 8 стр. 2;
- ЛЮТКИН ДМИТРИЙ АЛЕКСЕЕВИЧ** - [ORCID: 0009-0007-0646-6521]
 ведущий инженер-разработчик,
 ПАО «Сбербанк»,
 117312 Российская Федерация, г. Москва, ул. Вавилова, 19;
- ЗАЕВ РОМАН ИВАНОВИЧ** - [ORCID: 0009-0000-8657-9866]
 старший аналитик данных,
 АО «Северсталь-инфоком»,
 162602 Российская Федерация, Вологодская область, г. Череповец, ул. Ленина, 123А;
- РОМАНОВ АЛЕКСАНДР ЮРЬЕВИЧ** - [ORCID: 0000-0002-9410-9431]
 доцент, к.т.н.,
 Национальный исследовательский университет «Высшая школа экономики»,
 123458 Российская Федерация, г. Москва, ул. Таллинская, 34;
- СОЛОВЬЕВ РОМАН АЛЕКСАНДРОВИЧ** - [ORCID: 0000-0003-0312-452X]
 заместитель директора по инновационной деятельности,
 ООО «АльфаЧип»,
 124498 Российская Федерация, г. Москва, Зеленоград, пл. Шокина, 1 стр. 8;
- СЕРГЕЕВ ЮРИЙ СЕРГЕЕВИЧ** - [ORCID: 0009-0004-5984-7940]
 к.м.н., врач-онколог,
 Онкологический центр-1,
 ГКБ имени С.С. Юдина,
 117152 Российская Федерация, г. Москва, ул. Загородное шоссе, 18А стр. 1;
- АМОСОВ НИКИТА АЛЕКСАНДРОВИЧ** - [ORCID: 0009-0003-6222-3699]
 к.м.н., врач-уролог,
 ГБУЗ МО «МОНИКИ им. М.Ф. Владимирского»,
 129110 Российская Федерация, г. Москва, ул. Щеткина, 61/2.

Конфликт интересов, информация о клинической базе и финансировании
 Авторы заявляют об отсутствии конфликта интересов.