

АВТОМАТИЗАЦИЯ ПРОЦЕССОВ ЛУЧЕВОЙ ТЕРАПИИ: ОПТИМИЗАЦИЯ ОКОНТУРИВАНИЯ В ЛУЧЕВОЙ ТЕРАПИИ С ПОМОЩЬЮ МАШИННОГО ОБУЧЕНИЯ

Ю.А. Кудашкина, О.А. Рыжикова, А.А. Куфелкина, П.И. Блиганов, М.В. Черных
НМИЦ онкологии им. Н.Н. Блохина Минздрава России, Москва

AUTOMATION OF RADIOTHERAPY PROCESSES: OPTIMIZATION OF CONTOURING IN RADIOTHERAPY USING MACHINE LEARNING

Yu.A. Kudashkina, O.A. Ryzhikova, A.A. Kufelkina, P.I. Bliganov, M.V. Chernykh
N.N. Blokhin National Medical Research Center of Oncology of the Ministry of Health
of the Russian Federation, Moscow, Russia

Реферат

Внедрение технологий машинного обучения, в частности нейронных сетей, в медицину значительно изменило подходы к диагностике и лечению различных заболеваний. Одной из наиболее перспективных областей является лучевая терапия (ЛТ), где автоматизация процессов может существенно повысить точность и эффективность лечения. Автооконтурирование, выполняемое посредством автоматизированного определения целевых объемов мишеней и критических органов на основе нейронных сетей, может заменить традиционное оконтурирование в ручном режиме врачами-радиотерапевтами. Такой подход позволяет не только снизить временные затраты на обработку медицинских изображений, но и уменьшить риск возникновения ошибок, обусловленных человеческим фактором, при повышении качества планирования лечения.

Введение технологий искусственного интеллекта (ИИ) в процесс оконтурирования представляет собой многообещающее направление, способствующее повышению точности и эффективности лучевой терапии. В данной статье рассматривается методика создания базы данных для разработки и верификации моделей машинного обучения для автоматизации процесса оконтурирования мишени (опухоли или ложа опухоли) и критических органов. Решен ряд задач, включая анализ существующих проблем оконтурирования, сбор данных для обзора литературы по методам ИИ и для обучения нейросетей и интеграцию технологий в клиническую практику.

Ключевые слова: онкологические заболевания, лучевая терапия, искусственный интеллект, оконтурирование мишеней, модель машинного обучения, клиническая практика

Abstract

In recent years, the introduction of machine learning technologies, in particular neural networks, into medicine has significantly changed approaches to the diagnosis and treatment of various diseases. One of the most promising areas is radiation therapy (RT), where process automation can significantly improve the accuracy and efficiency of treatment. The possibility of introducing neural network-based autocontouring into the practice of LT to automatically determine the contours of target radiation exposure, which was traditionally performed manually by radiotherapists, can become an automatic process. This approach not only reduces time spent on processing medical images, but also reduces the risk of human error, improving the quality of treatment planning.

The introduction of artificial intelligence (AI) technologies into the delineation process represents a promising direction to improve the accuracy and efficiency of radiation therapy. This paper discusses a database methodology for developing and verifying machine learning models that will automate the delineation process of tumor structures and critical organs. A number of tasks are proposed, including analyzing existing delineation problems, writing a literature review on AI methods, collecting data for

training neural networks, and integrating the technology into clinical practice.

Key words: oncological diseases, radiation therapy, artificial intelligence, contouring, machine learning model, clinical practice

E-mail: kudashkina.work@gmail.com

<https://doi.org/10.52775/1810-200X-2025-106-2-79-91>

Введение

Онкологические заболевания, согласно данным Всемирной организации здравоохранения (ВОЗ), продолжают оставаться одной из основных причин (развития) заболеваемости и смертности по всему миру, занимая второе место после сердечно-сосудистых заболеваний по количеству новых случаев и уровню летальности [1]. Одной из значительных преград в успешном лечении онкологических заболеваний является их способность к метастазированию, что усложняет процесс лечения и является неблагоприятным фактором для жизни пациентов. К сожалению, онкологические заболевания часто диагностируются на поздних клинических стадиях, что снижает эффективность дальнейшего лечения [2].

Одним из методов лечения онкологических заболеваний является лучевая терапия (ЛТ), направленная на уничтожение опухолевых клеток или замедление их роста. ЛТ применяется не только в качестве самостоятельного метода лечения, но и в качестве адъювантной терапии после хирургического вмешательства с целью уничтожения оставшихся опухолевых клеток. Процесс ЛТ включает несколько ключевых этапов: топометрическую подготовку, определение мишеней (оконтурирование), планирование терапии, непосредственное лечение и контроль состояния пациента.

Точность определения границ опухоли имеет решающее значение для успешного проведения ЛТ. Недостаточная визуализация может неблагоприятно сказаться на результатах лечения. Таким образом, исследования, связанные с использованием искусственного интеллекта (ИИ) в ЛТ, представляют собой перспективное направление.

Целью работы является создание базы клинических данных о пациентах для разработки, обучения и верификации моделей ма-

шинного обучения, направленных на оконтуривание опухолевых очагов и критических структур. Для достижения поставленной цели необходимо решить следующие задачи:

- ✓ выявить проблемы, возникающие при оконтуривании опухолей и критических структур;
- ✓ представить литературные данные по методам ИИ при оконтуривании с учетом отступов;
- ✓ собрать клинические данные по локализациям и оконтуренным клиническим случаям для обучения нейросетей;
- ✓ протестировать различные варианты на корректность получаемых контуров;
- ✓ проанализировать полученные результаты с добавлением новых случаев для обучения нейросетей;
- ✓ интегрировать разработанные решения в клиническую практику.

Материал и методы

Обучающая выборка включает данные о 3000 пациентов со злокачественными новообразованиями различных нозологий. В базу данных для головного мозга были отобраны случаи ЛТ, проводимой на весь объем головного мозга, первичные опухоли ЦНС и метастазы в головном мозге. База данных об абдоминальной области, репродуктивных и мочевыводящих системах включала случаи рака пищевода, желудка, почек, поджелудочной железы, метастазов в забрюшинные лимфоузлы и малого таза, рака анального канала, предстательной железы, ЗНО женской репродуктивной системы, мочевого пузыря, прямой кишки.

Результаты

Все данные были получены в результате проведения КТ-топометрии, позволяющей определить объемы опухоли и здоровые органы. Система планирования (СП) позволяет подгружать серии снимков позитронно-эмиссионной томографии (ПЭТ) и магнитно-резонансной томографии (МРТ), которые в последующем интегрируются с серией снимков КТ-топометрии с помощью технологии Fusion. В результате создается объединенный файл – Fusion Image, состоящий из сопоставленных снимков двух видов исследований. База данных состоит из 3000 наборов данных: 1000 – головной мозг, 1000 – брюшная полость, 500 – малый таз мужской, 500 – малый таз женский. Наборы данных являются несбалансированными, так как количество снимков в каждом классе существенно различается, что может негативно сказываться на распознавательной способности алгоритмов глубокого обучения.

Далее планируется разделение всей выборки на обучающую, валидационную и тестовую выборки. В обучающую выборку будут включены 70 % изображений, что составляет 2100 наборов, выбранных случайным образом. Для валидации из обучающей выборки также случайным образом будет выбрано 20 % изображений. Оставшиеся 300 наборов будут использованы для тестирования.

Анализ существующих методик оконтуривания в лучевой терапии

Современная практика (ЛТ) зависит от методов оконтуривания, которые важны для определения границ зоны облучения. В клинической практике используются ручные и автоматизированные методики оконтуривания. Ручное оконтуривание требует участия врача, который определяет контуры опухоли и окружающих тканей на основе визуальных данных. Автооконтуривание в СП автоматизирует процесс, но результаты часто требуют редактирования в связи с наличием нечеткости границ структур [3]. Алгоритмы могут не всегда правильно дифференцировать опухолевые и здоровые ткани, что увеличивает риск недостаточного или избыточного лучевого воздействия на здоровые ткани.

Таким образом, несмотря на прогресс в автоматизации оконтуривания, необходимо

повышать точность алгоритмов и ручных методов. Сочетание ручных и автоматических методик с применением технологий ИИ может улучшить оконтуривание и минимизировать вызванные человеческим фактором ошибки.

Модальности различных локализаций в лучевой терапии

Основной модальностью для планирования лучевой терапии органов брюшной полости и малого таза, как и в случае с головным мозгом, является КТ. Однако данные МРТ, благодаря применению контрастирования мягких тканей, позволяют лучше визуализировать структуры, что делает их ценным инструментом для уточнения границ. Но при этом необходимо учитывать не только отличные параметры МРТ-сканирования, но и различия между самими МРТ-сканерами и их режимами работы. Данные МРТ могут поступать из множества сканеров различных типов, каждый из которых может иметь свои технические особенности и данные отличающихся режимов исследования, таких как T_1 -взвешенные и T_2 -взвешенные последовательности (наборы параметров сканирования). Эти последовательности характеризуются разными типами контрастности изображений, что приводит к вариативности в визуализации тканей. Такие различия между сканерами и последовательностями требуют специальных методов подготовки данных и обучения моделей искусственного интеллекта, чтобы обеспечить устойчивость и надежность алгоритмов в условиях таких вариаций.

Головной мозг

При подготовке к проведению курса ЛТ радиотерапевты оконтуривают критические структуры, лучевую нагрузку на которые необходимо в дальнейшем оценить и сопоставить с толерантными значениями. В работе выделено три локализации: головной мозг, брюшная полость и малый таз. Для каждой локализации выделены структуры, которые необходимо оконтурить при подготовке к ЛТ. Данные представлены ниже в виде таблиц (табл. 1–6).

Анатомия головного мозга весьма сложна, и структуры, выявляемые при МРТ, часто плохо различимы по данным КТ. Кроме того, качество изображений может значительно

Таблица 1

Критические структуры, оконтуренные в головном мозге, на примере облучения всего объема головного мозга (режим ЛТ “Whole Brain Radiation Therapy”)

BODY	Область тела пациента
Bones	Кости
Brain	Мозг
BrainStem	Ствол мозга
BrainStem_PRV	Ствол мозга Pulseratevariability (+6 мм к контуру ствола мозга)
Cochlea_L	Ушная раковина Левая
Cochlea_L_PRV	Ушная раковина ЛевоеPulseratevariability (+6 мм к контуру)
Cochlea_R	Ушная раковина Правая
Cochlea_R_PRV	Ушная раковина Правая Pulseratevariability (+6 мм к контуру)
Eye_L	Левое глазное яблоко
Eye_R	Правое глазное яблоко
Hippocampi	Гиппокамп
Lens_L	Левый хрусталик
Lens_R	Правый хрусталик
OpticChiasm	Перекрест зрительных нервов
OpticChiasm_PRV	Перекрест зрительных нервов Pulseratevariability(+6 мм к контуру)
OpticNerve_L	Зрительный нерв Левый
OpticNerve_L_PRV	Зрительный нерв Левый Pulseratevariability (+6 мм к контуру)
OpticNerve_R	Зрительный нерв Правый
OpticNerve_R_PRV	Зрительный нерв Правый Pulseratevariability (+6 мм к контуру)
SpinalCord	Спинальный мозг
SpinalCord_PRV	Спинальный мозг Pulseratevariability (+6 мм к контуру спинного мозга)

варьировать в зависимости от толщины среза и плоскости сканирования, а также последовательности МРТ. Радиотерапевт обязан уделять особое внимание деталям и четко оконтуривать критические структуры, такие как ствол головного мозга, хрусталик и глазные яблоки, зрительные нервы, улитки, гиппокамп (табл. 1, 2, рис. 1) [4].

МРТ широко известна своей способностью создавать высокодетальные изображения мягких тканей, благодаря использованию сильных магнитных полей и радиоволн. Это делает МРТ особенно полезной для визуализации головного мозга, где важно дифференцировать

Таблица 2

Облучаемые объемы, оконтуренные в головном мозге

GTV	GrossTumorVolume – макроскопический объем опухоли
GTVp_CT	GrossTumorVolumeofprimary (по КТ) – макроскопический объем опухоли (КТ)
GTVp_MR	GrossTumorVolumeofprimary (по МРТ) – макроскопический объем опухоли (МРТ)
GTVp_PT	GrossTumorVolumeofprimary (по ПЭТ) – макроскопический объем опухоли (ПЭТ)
CTV	ClinicalTargetVolume – клинический объем мишени
PTV	PlanningTargetVolume – планируемый объем мишени




Рис. 1. Синусы твердой мозговой оболочки (вид сверху): 1 – гипофиз; 2 – зрительный нерв; 3 – внутренняя сонная артерия; 4 – глазодвигательный нерв; 5 – клиновидно-теменной синус; 6 – блоковый нерв; 7 – глазной нерв; 8 – верхнечелюстной нерв; 9 – тройничный узел; 10 – нижнечелюстной нерв; 11 – средняя менингеальная артерия; 12 – отводящий нерв; 13 – нижний каменный синус; 14 – верхний каменный синус, сигмовидный синус; 15 – базиллярное венозное сплетение; поперечный синус; 16 – пещеристый венозный синус, сток синусов; 17 – передний и задний межпещеристые синусы; 18 – верхняя глазная вена



Рис. 2. Fusion Image (совмещение снимков разметочного КТ и снимков МРТ)

типы тканей, таких как серое вещество, белое вещество, спинномозговую жидкость. Однако у МРТ есть свои ограничения, связанные с большими временными затратами создания изображений в сравнении с КТ [5]. На рис. 2–4 представлены совмещенные снимки разметочного КТ и МРТ, используемые при оконтуривании объемов и критических органов при облучении головного мозга.

В задачах сегментации опухолей головного мозга модели часто оцениваются с использованием комбинации Accuracy (достоверность, аккуратность), Recall, или Sensitivity (полнота, чувствительность), Specificity (специфичность), F-score (F-мера), а также специализированных метрик, таких как DSC и HD (коэффициент сходства Дайса и расстояние Хаусдорфа). Эта комбинация обеспечивает надежную оценку, учитывая как границы, так и объемные свойства опухолей. Метрики на уровне поражений, такие как lesion-wise DSC и 95HD (дискриминация по поражениям или по очагам с использованием коэффициента сходства Дайса и 95-го перцентиля расстояния Хаусдорфа), все чаще используются для оценки качества модели на уровне отдельных поражений, что дает более детальное представление о точности сегментации в сценариях с несколькими очагами. В недавнем исследовании в клинических исследованиях BraTS 2023 модели глубинного обучения Tumor Det Net [6] были использованы для оценки способности классифицировать различные типы опухолей с высокой точностью. В




Рис. 3. Определение облучаемых объемов головного мозга в режиме “WholeBrainRadiationTherapy” – CTV и PTV

рамках обучения простых моделей, таких как U-Net (архитектура нейронной сети), возможно использовать изображения на основе модели HaN-Seg (Hierarchical Attention Network for Segmentation) в целях успешного сегментирования анатомических структур, таких как, например, глазные яблоки. Тем не менее, ни одно из представленных решений не достигло удовлетворительных результатов в задаче сегментации перекреста зрительных нервов. Для этой задачи применялись стандартизированные МРТ-изображения с толщиной срезов МРТ не




Рис. 4. Определение объемов критических органов при облучении головного мозга в режиме “WholeBrainRadiationTherapy”

Таблица 3

**Сводные литературные данные для опухолей головы-шеи по модальностям
диагностических данных на этапе подготовки больных к ЛТ**

Название набора данных	Число случаев	Модальности	Размер матрицы	Количество срезов	Размер воксела	Число органов в зоне риска
GLIS-RT Shusharina and Bortfeld (2021)	230	MPT (T_{1c} , 2D T_2 -FLAIR)	–	–	–	6–12
Burdenko-GBM-ProgressionZolotova (2023)	180	MPT (T_1 , T_{1c} , T_2 , T_2 -FLAIR), КТ	–	–	–	8
MindboggleKleinetal. (2017)	101	MPT (T_1)	–	–	–	4
HaN-SegPodobnik et al. (2022)	42	MPT (T_1), КТ	КТ: 512×512; 1024×1024 MPT: 512×512	КТ: 116~323 MPT: 40~152	2×0,47×0,47 ~ 5×1,56×1,56	30
SegRapAstarakieta. (2023)	400	КТ	КТ: 512×512; 1024×1024	–	3×0,43×0,43 ~ 3×1,34×1,34	45
StructSegShi (2019)	60	КТ	–	–	–	22
TangTangetal. (2019)	140	КТ	–	–	2,5×2×3	28

менее 5 мм, которые ко-регистрировались с КТ. Сочетание данных МРТ и КТ показало улучшенные результаты, но этого недостаточно для разработки эффективного медицинского программного обеспечения. Учитывая возможность отсутствия МРТ-исследований пациента, были рассмотрены методы, использующие исключительно данные КТ. Для анализа изображения головного мозга применялся набор данных, специально разработанный для задач сегментации и анализа изображений – SegRap (Segmentation for Rapid Annotation of Pathology), состоящий из 400 КТ-сканов. Как продемонстрировано в предыдущих исследованиях, подобный объем данных в некоторых случаях оказывается достаточным для получения приемлемых результатов сегментации различных структур мозга. Однако низкий контраст КТ-изображений при сегментации сложных анатомических структур, таких как перекрест зрительных нервов, ограничивает точность.

Таким образом, успешное обучение нейронной сети на основе КТ-изображений требует использования более сложных моделей, способных работать со структурами с низким контрастом. Увеличение сложности модели влечёт за собой потребность в большем количестве данных для её обучения. Учитывая результаты предыдущих исследований и требования к точности, минимальное количество КТ-серий, необходимое для обучения модели на каж-

дом органе, следует оценивать как не менее 500, хотя для более сложных структур, таких как перекрест зрительных нервов, может потребоваться значительно больше данных. Тем не менее, для большинства основных анатомических структур подобный объем данных может считаться достаточным.

Для повышения точности сегментации также могут быть использованы серии МРТ-изображений, представленные одной из следующих последовательностей: T_{1w} , T_{1c} , T_{2w} или T_2 -FLAIR. Стоит отметить, что количество различных последовательностей и их комбинаций для одного пациента может значительно варьировать. Поскольку контуры фиксируются только по КТ-сериям, для определённого количества КТ-серий из предыдущего пункта необходимо наличие хотя бы одной последовательности МРТ (табл. 3).

Брюшная полость и малый таз

Органы брюшной полости и малого таза имеют сходство относительно друг друга, ввиду их частичного пересечения, поэтому для обеих зон будут одинаковые требования по их количеству. В большинстве исследований для сегментации органов брюшной полости и малого таза используется от нескольких сотен до нескольких тысяч КТ- и МРТ-сканов, что позво-

ляет моделям достигать приемлемой точности при распознавании сложных анатомических структур. Необходимое количество данных сильно варьирует от органа к органу ввиду их разницы в структурах разных органов. Основываясь на других исследованиях, необходимое количество данных для обучения модели также оценивается в 400 случаев для каждой отдельной локализации [7]. Отдельные сложные органы могут потребовать большего количества аннотированных данных, однако для основной части органов такого количества будет достаточно. Также отметим, что нет исследований по автоматической сегментации отдельных органов, что не позволяет в полной мере оценить необходимое количество данных для сегментирования.

Анализ органов брюшной полости требует особого внимания из-за разнообразия анатомических структур и их изменчивости и уникальности для каждого пациента в разные моменты времени. Важным аспектом является прицельное оконтуривание жизненно важных органов и патологических образований для планирования ЛТ.

Органы брюшной полости и малого таза могут претерпевать значительные изменения в зависимости от состояния и положения пациента. Например, объем легких может быть различным по своей величине в зависимости от фазы дыхания, состояние кишечника зависит от наличия газов или калового содержимого. Описанные анатомические вариации требуют разработки методов, устойчивых к такому роду изменений, а также учета временной изменчивости органов при анализе данных. Нужно также упомянуть анатомическое разнообразие: множество органов, таких как печень, желудок и почки, могут отличаться по форме и размеру у разных людей, что затрудняет задачу оконтуривания. Расположение и наполнение кишечника могут варьировать, создавая дополнительные трудности для автоматической сегментации.

Брюшная полость

Процесс оконтуривания объемов облучения и критических органов осуществляется после создания совмещенных данных разметочной серии КТ-изображений органов брюшной полости с данными других диагностических исследований (МРТ ОБП с в/в контрастированием или ПЭТ/КТ всего тела с туморотропным РФП). В определенных клинических ситуа-




Рис. 5. Анатомические ориентиры деления пищевода на отделы: шейный, верхнегрудной, среднегрудной, нижнегрудной

циях, например, при создании плана ЛТ рака поджелудочной железы или метастазов в печень, в целях лучшей визуализации мишеней и дифференцировки органов, перед проведением разметочной КТ может быть выполнено дополнительное внутривенное и/или пероральное введение контрастных препаратов.

Рассмотрим локализацию брюшной полости на примере ниже-грудного отдела пищевода, границы отделов пищевода и критические органы (рис. 5, табл. 4, 5), которые включают:

- ✓ Шейный: от перстневидного хряща до входа в грудную клетку – 5–18 см от резцов.
- ✓ Верхний грудной: от входа в грудную клетку до бифуркации трахеи – 18–24 см.
- ✓ Средне-грудной: от бифуркации трахеи до участка выше гастро-эзофагеального соустья – 24–32 см.
- ✓ Нижне-грудной: гастро-эзофагеальное соустье – 32–40 см.

Критические органы, которые необходимо оконтурить:

- ✓ легкие (по отдельности);
- ✓ сердце;
- ✓ спинной мозг;
- ✓ пищевод на всем протяжении (для анализа гистограммы дозы-объем) [8].

Таблица 4

**Оконтуренные критические структуры
на примере планирования ЛТ пациента
с ЗНО пищевода**

Aorta	Аорта
Bladder	Мочевой пузырь
BODY	Область тела пациента
Bones	Кости
Bowelbag	Тонкий кишечник
Bowel_Bag	Тонкий кишечник
BrachialPlexs	Брахиальный сплетение
BrachialPlexus_L	Брахиальный сплетение Левое
BrachialPlexus_R	Брахиальный сплетение Правое
BrainStem	Ствол мозга
BrainStem_PRV	Стволмозга Pulse rate variability (+6 ммконтур)
Carina	Карина
Cauda_Equina	Конский хвост
Cauda_Equina_PRV	Конский хвост Pulseratevariability (+6 мм к контуру)
CaudaEquina	Конский хвост
CaudaEquina_PRV	Конский хвост Pulseratevariability (+6 мм к контуру)
Cochlea_L	Ушная раковина Левая
Cochlea_R	Ушная раковина Правая
Colon	Ободочная кишка
Duodenum	Двенадцатиперстная кишка
Esophagus	Пищевод
Eye_L	Левый глаз
Eye_R	Правый глаз
Femur_Head_L	Головка бедренной кости Левая
Femur_Head_R	Головка бедренной кости Правая
Femur_Heads	Головки бедренных костей
GlnD_Thyroid	Щитовидная железа
Heart	Сердце
Jejunum_Ileum	Тонкая кишка (или подвздошная)
Kidney_L	Почка Левая
Kidney_R	Почка Правая
Kidneys	Почки
Larynx	Гортань
Lens_L	Левый хрусталик
Lens_R	Правый хрусталик
Liver	Печень
Lobe_Temporal	Височная доля
Lung_L	Левое легкое
Lung_R	Правое легкое
Lungs	Легкие
Mandible_bone	Челюсть
Musc_Constrict	Мышцы сжатия
OpticChiasm	Перекрест зрительных нервов
OpticChiasm_PRV	Перекрест зрительных нервов Pulseratevariability (+6 мм к контуру)
OpticNerve_L	Зрительный нерв Левый
OpticNerve_R	Зрительный нерв Правый
Oral_Cavity	Полость рта
Pancreas	Поджелудочная железа
Parotid_L	Околоушная железа Левая
Parotid_R	Околоушная железа Правая
Parotids	Околоушные железы
Rectum	Прямая кишка
Renal_Cortex	Корковое вещество почки
Renal_Hilum	Хилус почки
Ribs	Ребра
Skin	Кожа
SpinalCord	Спинной мозг
SpinalCord_PRV	Спинной мозг Pulseratevariability (+6 мм к контуру)
SpinalCord_PRV05	Спинной мозг Pulseratevariability (+5 мм к контуру)
Spleen	Селезенка
Stomach	Желудок
Submandibular_L	Поднижнечелюстная железа Левая
Submandibular_R	Поднижнечелюстная железа Правая

Таблица 5

**Облучаемые объемы, оконтуренные
в брюшной полости на примере пищевода**

GTV	GrossTumorVolume – макроскопический объем опухоли
GTVn	GrossTumorVolume – макроскопический объем
GTVp_CT	GrossTumorVolume of primary – макроскопический объем (поКТ)
GTVp_MR	Gross Tumor Volume of primary – макроскопический объем (поМРТ)
GTVp_PT	Gross Tumor Volume of primary – макроскопический объем (поПЭТ)
CTV	ClinicalTargetVolume – клинический объем мишени
CTVn	Clinical Target Volume – клинический объем
CTVp	ClinicalTargetVolumeofprimary – клинический объем первичной опухоли
PTV	PlanningTargetVolume – планируемый объем мишени

Далее представлены примеры выбора облучаемых объемов и критических органов брюшной (Ventral) полости (рис. 6, 7).

В статье [9] были получены метрики оценки Dice Score (коэффициент сходства Дайса) для сегментации двенадцатиперстной кишки, равные 0,84 по данным МРТ из исследования NAKO (National Cohort Study of Health); 0,64 по данным также МРТ AMOS22 (Abdominal Multi-Organ Segmentation Challenge) и 0,8 по данным КТ AMOS22 (Abdominal Multi-Organ Segmentation Challenge). Это показывает различные




Рис. 6. Выбор облучаемых объемов пищевода: выделенные объемы GTV, CTV, PTV




Рис. 7. Оконтурированные критические органы при раке пищевода в системе планирования Eclipse

уровни точности в зависимости от используемого набора данных.

Исследование [10] продемонстрировало успешное применение архитектуры модели SegVol (Segmented Volumetric) с механизмом “zoom-out-zoom-in” (масштабирование для более детального изучения структур) для повышения точности сегментации. В этом исследовании использовался набор данных с 90 000 КТ-сканов, из которых 6 000 были аннотированы. Средний Dice Score (среднее значение показателя коэффициента сходства Дайса) для сегментации аорты составил 0,75, что указывает на умеренную точность модели в данной задаче.

В статье [11] был представлен новый подход на основе большого набора данных для обучения и повторного обучения (Multi-Dataset Learning and re-Training), который нацелен на создание универсальной модели для медицинской сегментации изображений. Эта модель способна сегментировать различные структуры, включая двенадцатиперстную кишку. Модель Multi Talent была обучена на 13 наборах данных абдоминальных КТ-сканов, которые содержали 47 классов, с общим количеством серий равным 1 500. Она продемонстрировала улучшенные результаты сегментации по сравнению с моделями, обученными на каждом наборе данных отдельно, а также использующими несколько наборов данных для обучения. В исследовании рассматривались различные архитектуры, такие как nnU-Net (архитектура автоматически адаптируемой модели), Swin U-Net (архитектура сдвинутых окон для обработки изображений), Resenc U-Net (архитектура с

использованием остаточных блоков для передачи информации через слои) и Swin UNETR (архитектура сдвинутых окон с объединением с U-net с механизмами трансформеров). Средний Dice Score для сегментации двенадцатиперстной кишки составил 0,76, что подтверждает умеренную точность Multi Talent в этой задаче.

Малый таз

На рис. 8 представлены анатомические структуры малого таза.

Проведение диагностической МРТ с контрастированием является обязательным условием для проведения курса дистанционной ЛТ опухолей, расположенных в области малого таза. Данный диагностический метод обладает высокой чувствительностью и специфичностью в определении опухолей данной локализации, а также позволяет оптимально дифференцировать анатомические границы здоровых органов и тканей. Лишь в условиях, когда пациенту противопоказано проведение МРТ с контрастным усилением, данный метод может быть заменен на КТ с или без в/в контрастированием. Стоит отметить, что в определенных клинических ситуациях, когда по данным МРТ опухолевые очаги не определяются, но при этом обнаруживается метаболически активный патологический субстрат, выявляемый по данным ПЭТ/КТ всего тела с туморотропным РФП, данные последнего могут быть использованы для создания оптимального плана лучевой терапии.

На рис. 9–11 представлены снимки разметочных КТ и МРТ, используемые при оконтур-




Рис. 8. Анатомические структуры малого таза

Таблица 6
Подлежащие оконтуриванию критические
структуры в малом тазу на примере
облучения мочевого пузыря

Bladder	Мочевой пузырь
Bladder_Wall	Стена мочевого пузыря
BODY	Область тела пациента
Bones	Кости
Bowel_Bag	Тонкий кишечник
CaudaEquina	Конский хвост
CaudaEquina_PRV	Конский хвост PulseRateVariability (+6 мм к контуру)
Colon_Sigmoid	Сигмовидная кишка
Femur_Head_L	Головка бедренной кости Левая
Femur_Head_R	Головка бедренной кости Правая
Femur_Heads	Головки бедренных костей
Femur_Heads_L	Головки бедренных костей Левая
Femur_Heads_R	Головки бедренных костей Правая
Rectum	Прямая кишка
Skin	Кожа
Spinal_Cord	Спинальный мозг
Spinal_Cord_PRV	Спинальный мозг PulseRateVariability (+6 мм к контуру)
SpinalCord	Спинальный мозг
SpinalCord_PRV	Спинальный мозг PulseRateVariability (+6 мм к контуру)

ривании объемов и критических органов при облучении опухоли мочевого пузыря (табл. 6).

Методика оконтуривания с использованием ИИ включает в себя обработку предварительно полученных медицинских изображений (например, КТ и МРТ) с применением алгоритмов глубокого обучения. Эти алгоритмы обучаются на больших объемах данных, что позволяет их идентифицировать и оконтуривать опухолевые образования и органы-мишени с высокой степенью точности. После автоматического оконтуривания врач может просмотреть результаты и внести необходимые коррективы, если это требуется.

Сегментация мочевого пузыря является важной задачей в планировании лечения заболеваний органов брюшной полости. В исследовании [12] использовалась сверточная нейронная сеть (CNN) для автоматической сегментации целевого объема и органов риска при раке прямой кишки. Набор данных включал 105 па-




Рис. 9. Fusion Image (наложение снимков разметочного КТ и снимков МРТ) – фронтальный вид




Рис. 10. Выбор облучаемых объемов мочевого пузыря (выделенные объемы GTV, CTV, PTV)




Рис. 11. Оконтуренные критические органы при раке мочевого пузыря в системе

циентов раком прямой кишки. Средний Dice Score для сегментации мочевого пузыря составил 0,90, что указывает на высокую точность сегментации и приемлемость автоматических контуров для клинического применения.

В исследовании [13] использовалась архитектура D-Net (архитектура нейронной сети для сегментации изображений), состоящая из динамических крупных свёрточных ядер (Dynamic Large Kernel, DLK) и модуля динамического слияния признаков (Dynamic Feature Fusion, DFF), что позволило значительно улучшить качество сегментации. Набор данных включал 300 КТ-сканов из исследования MICCAI (The Medical Image Computing and Computer Assisted Intervention Society) 2021 AMOS Challenge (Abdominal Multimodal Analysis Challenge). Средний Dice Score для сегментации мочевого пузыря составил 0,91, что подчеркивает эффективность предложенного подхода.

В исследовании [10] была использована архитектура Seg Vol, поддерживающая как пространственные, так и семантические подсказки для интерактивной сегментации. В набор данных вошли 90 000 не аннотированных КТ-серий и 6 000 аннотированных КТ-серий. Средний Dice Score для сегментации мочевого пузыря составил 0,91, что свидетельствует о высоком качестве сегментации. Использование механизма zoom-out-zoom-in позволило модели эффективно и точно выполнять сегментацию объемных изображений.

В статье [14] было показано, что автоматическая сегментация внутренней и наружной стенки при МРТ представляет собой сложную задачу из-за значительных изменений формы мочевого пузыря, неоднородности интенсивности в моче, вызванной артефактами движения, слабых границ и сложного распределения интенсивности фона. Эти факторы усложняют точное определение границ и требуют использования современных методов глубокого обучения для повышения точности. Для сегментации стенок мочевого пузыря применялись различные архитектуры глубокого обучения, включая FCN (Fully Convolutional Networks), U-Net, и V-Net (3D сегментация данных). Dice Score для многих методов сегментации стенок мочевого пузыря на основе глубоких нейронных сетей достигает значений 0,99. Тем не менее, не все работы смогли получить настолько хорошие результаты, поэтому средний Dice Score по 10 работам составил 0,9.

Искусственный интеллект способен значительно повысить уровень автоматизации в процессе тривиального оконтуривания, что в свою очередь может сократить время на обработку данных и повысить точность оконтуривания. Литературные данные показывают, что применение ИИ в лучевой терапии достигает значительных результатов: автоматизированные методы показывают сравнимые или даже превосходящие результаты по сравнению с ручным оконтуриванием, что подтверждается рядом исследований. Применение ИИ в процессе оконтуривания способствует повышению эффективности и точности лечения, а также снижению нагрузки на врачей. Это обеспечивает более быстрый и качественный процесс подготовки к облучению, что, в свою очередь, может привести к улучшению исходов лечения и повышению уровня безопасности пациентов.

Обсуждение

Автоматизация процесса оконтуривания органов и опухолей с использованием искусственного интеллекта (ИИ) является ключевой задачей для повышения эффективности и точности ЛТ. Методы глубокого обучения позволяют ускорить топометрическую подготовку для дальнейшего планирования ЛТ. В последние годы нейронные сети существенно изменили подходы к анализу медицинских изображений, предлагая новые эффективные решения для классификации, сегментации и распознавания изображений. Эти методы значительно влияют на обработку медицинских данных, обеспечивая быструю и точную сегментацию структур, что важно для ЛТ. Подготовка данных включает процедуры нормализации интенсивности, процессы изменения размерности выборки данных (ресемплинга) и процессы создания новых измененных данных на основе существующих (аугментации), что повышает точность и надежность алгоритмов в процессе обучения и распознавания. Эти этапы помогают улучшить однородность данных, снизить искажения и адаптировать модели к различным клиническим ситуациям, что особенно важно для 3D-обработки медицинских данных, таких как МРТ и КТ.

В клинической практике автоматизация оконтуривания с применением ИИ демонстрирует наибольшую ценность в минимизации вреда здоровым тканям. Например, при анали-

зе головного мозга требуются специализированные алгоритмы, которые способны точно распознавать структурные и контекстные особенности, чтобы защитить жизненно важные функциональные зоны от избыточного облучения.

При сегментации органов брюшной полости и малого таза важно учитывать анатомическое разнообразие и высокую вариативность в зависимости от состояния пациента. Адаптивные алгоритмы, которые учитывают временные и физиологические изменения, позволяют более точно оконтурить критически важные структуры и опухоли, снижая риск для пациента. В этой связи акцентируется внимание на разработке устойчивых алгоритмов, которые способны адаптироваться к различным параметрам МРТ- и КТ-сканов, что обеспечивает их надежность и точность.

Современные архитектуры, такие как модифицированные U-Net, Mask R-CNN (архитектура генерации масок объектов), UNETR (архитектура с симметричной структурой кодировщика-декодировщика с включением элементов трансформеров) и Conv Ne Xt (архитектура новой «эволюции» сверточной сети), предоставляют эффективные методы интеграции пространственных и семантических признаков в анализ данных, включая работу с мультимодальными данными (КТ и МРТ). Эти модели дополнены методами самообучения и полуручного обучения, что повышает точность и снижает зависимость от ручной разметки, повышая надежность и клиническую применимость решений на основе ИИ. Эти подходы уже успешно внедряются в клиническую практику через автоматизированные системы для ЛТ. На рынке доступны решения, такие как Limbus AI, MIM Maestro и RayStation, которые объединяют ИИ, облачные технологии и адаптивное оконтуривание. Эти системы обеспечивают высокую производительность, а также гибкость настройки и совместимость с клиническими стандартами, что улучшает качество планирования и эффективность радиотерапевтических процедур, уменьшая ручные затраты и упрощая документооборот.

Выводы

Внедрение технологий ИИ и методов глубокого обучения в процесс оконтуривания органов и опухолей значительно повышает точ-

ность подведения дозы к опухоли. Автоматизация данного процесса не только оптимизирует топометрическую подготовку и упрощает планирование радиотерапевтических процедур, но и минимизирует риски облучения жизненно важных структур. Внедрение автоматизированных систем ИИ открывает новые горизонты для ЛТ, обеспечивая гибкость настройки и улучшая качество планирования облучения больных. Кроме этого, внедрение ИИ ускорит процедуру внедрения стандартов оконтуривания на этапе предлучевой подготовки онкологических больных в профильных учреждениях.

Список литературы

1. <https://www.who.int/ru>.
2. Seyfried TN, Huysentruyt LC On the origin of cancer metastasis. Crit Rev Oncog. 2013; 18 (1-2): 43-73. <https://doi.org/10.1615/critrevoncog.v18.i1-2.40>.
3. Brouwer C, Boukerroui D, Oliveira J. et al. Assessment of manual adjustment performed in clinical practice following deep learning contouring for head and neck organs at risk in radiotherapy. Physics and Imaging in Radiation Oncology. 2020 Oct 14; 16: 54-60. <https://doi.org/10.1016/j.phro.2020.10.001>.
4. Горчаков ВН, Сергеева ИГ, Тулупов АА. Нейрохирургическая анатомия головного мозга: Учебное пособие. Новосибирск. 2015. 124.
Gorchakov VN, Sergeeva I G, Tulupov AA. Neurosurgical anatomy of the brain: Atutorial. Novosibirsk. 2015; 124 (In Russ).
5. Devic S. MRI simulation for radiotherapy treatment planning. Med Phys. 2012; 39 (11): 6701-11. <https://doi.org/10.1118/1.4758068>.
6. Ullah N, Javed A, et al. A unified deep learning model for brain tumor detection and classification. PLoS One. 2023; 18 (9): e0291200. <https://doi.org/10.1371/journal.pone.0291200>.
7. Kart T, Fischer M, et al. Deep learning based automated abdominal organ segmentation in the UK Biobank and German National Cohort magnetic resonance imaging studies. Investigative Radiology. 2021 Jun 1; 56 (6): 401-8. <https://doi.org/10.1097/RLI.0000000000000755>.
8. Деньгина Н, Лихачева А, Митин Т, Усыйчкин С, Черных М, Панкратов А. Краткие методи-

- ческие рекомендации по лучевой терапии опухолей головного мозга. RUSSCO, 2017.
9. Haentze H. et al. MRSegmentator: Robust Multi-Modality Segmentation of 40 Classes in MRI and CT. MRSegmentator. November 18, 2024. <https://doi.org/10.48550/arXiv.2405.06463>.
 10. Du Y, et al. Segvol: Universal and interactive volumetric medical image segmentation. 38th Conference on Neural Information Processing Systems (NeurIPS 2024). 12 Feb. 2025. <https://doi.org/10.48550/arXiv.2311.13385>.
 11. Ulrich C, et al. Multitalent: A multi-dataset approach to medical image segmentation. International Conference on Medical Image Computing and Computer-Assisted Intervention. Medical Image Computing and Computer Assisted Intervention – MICCAI. 2023; 648-58. https://doi.org/10.1007/978-3-031-43898-1_62.
 12. Huang Y, et al. Clinical evaluation of the convolutional neural network-based automatic delineation tool in determining the clinical target volume and organs at risk in rectal cancer radiotherapy. Oncology Letters. 2024; 28 (5): 539. <https://doi.org/10.3892/ol.2024.14672>. eCollection 2024 Nov.
 13. Yang J, et al. D-net: Dynamic large kernel with dynamic feature fusion for volumetric medical image segmentation. <https://doi.org/10.48550/arXiv.2403.10674>.
 14. Bandyk MG, et al. MRI and CT bladder segmentation from classical to deep learning based approaches: Current limitations and lessons. Computers in Biology and Medicine. 2021; 134: 104472. <https://doi.org/10.1016/j.compbimed.2021.104472>. Epub. 2021 May 18.

Конфликт интересов. Авторы заявляют об отсутствии конфликта интересов.

Финансирование. Исследование не имело спонсорской поддержки.

Участие авторов. Статья подготовлена с равным участием авторов.

Поступила: 19.03.2025. Принята к публикации: 10.06.2025.

Conflict of interest. The authors declare no conflict of interest.

Financing. The study had no sponsorship.

Contribution. Article was prepared with equal participation of the authors.

Article received: 19.03.2025. Accepted for publication: 10.06.2025.