

<https://doi.org/10.33878/2073-7556-2022-21-1-26-36>



Применение искусственного интеллекта в МРТ диагностике рака прямой кишки

Елигулашвили Р.Р.¹, Зароднюк И.В.¹, Ачкасов С.И.¹, Белов Д.М.¹,
Михальченко В.А.¹, Гончарова Е.П.¹, Запольский А.Г.², Сулова Д.И.²,
Ряховская М.А.², Никитин Е.Д.³, Филатов Н.С.³

¹ФГБУ «НМИЦ колопроктологии имени А.Н. Рыжих» Минздрава России (ул. Саяма Адила, д. 2, г. Москва, 123423, Россия)

²АО «Национальный Центр Сервисной Интеграции» (Бережковская набережная, д. 38, стр. 1, этаж 3, помещение 1, комната 1, г. Москва, 121059, Россия)

³ООО «Медицинские Скрининг Системы» (ул. Циолковского, д. 4, офис 301, г. Калуга, 248000, Россия)

РЕЗЮМЕ

ЦЕЛЬ ИССЛЕДОВАНИЯ: разработка систем поддержки принятия врачебного решения при МРТ-диагностике рака прямой кишки: локализация и сегментация первичной опухоли.

ПАЦИЕНТЫ И МЕТОДЫ: в работу было включено 450 МРТ-исследований больных раком прямой кишки (РПК) и 450 МРТ-исследований пациентов без опухолевого поражения прямой кишки. Все пациенты с опухолями прямой кишки имели гистологическую верификацию злокачественного процесса. Данные собирались в коронарной и аксиальной проекциях T2-ВИ (МРТ Philips Achieva 1,5 Тл). Разметка объектов проводилась только для проекций T2-ВИ, где сегментировалась область интереса — прямая, сигмовидная кишка и опухоль. Для разметки МРТ-изображений была использована программа ITK-Snap. Провалидированные исследования и разметка использовались для создания модели машинного обучения, демонстрирующей возможности набора данных для построения систем поддержки принятия врачебного решения. Для создания базовой модели искусственного интеллекта использовались нейросети SegResNet, TransUnet, 3D Unet. Набор пациентов и непосредственно разметка МРТ-исследований были проведены врачами ФГБУ «НМИЦ колопроктологии им А.Н. Рыжих» Минздрава России. Разработка модели искусственного интеллекта, валидация разметки выполнялась сотрудниками ООО «Медицинские Скрининг Системы», АО «Национальный Центр Сервисной Интеграции».

РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЯ: коэффициенты близости (DSC) различных нейросетей составили: TransUnet — 0.33, SegResNet — 0.50, 3DUnet — 0.42. Диагностическая эффективность нейросети SegResNet в выявлении опухолей прямой кишки с добавлением отрицательных примеров и постобработкой составила: точность — 77,0%; чувствительность — 98,1%; специфичность — 45,1%; положительная прогностическая ценность — 72,9%; отрицательная прогностическая ценность — 94,1%. На данном этапе ИИ обладает довольно высокой чувствительностью и точностью, что говорит о высокой диагностической эффективности в отношении визуализации первичной опухоли и определении ее локализации в прямой кишке. Однако специфичность метода пока на неудовлетворительном уровне (45,1%), что говорит о высоком проценте ложноположительных результатов у здоровых пациентов и не позволяет использовать модель в качестве скринингового метода на данном этапе ее развития.

ЗАКЛЮЧЕНИЕ: собранный датасет МРТ-исследований и их разметка, позволили получить ИИ-модель, которая позволяет решать задачу сегментирования опухоли прямой кишки и определение ее локализации. Следующим этапом развития ИИ является улучшение ее специфичности, расширение анализируемых параметров, таких как глубина инвазии опухоли, визуализация метастатических лимфатических узлов и статуса края резекции. Для дальнейшей разработки метрики модели и улучшения ее диагностических возможностей, следует экспериментировать с параметрами обучения и увеличивать набор данных.

КЛЮЧЕВЫЕ СЛОВА: МРТ, магнитно-резонансная томография, искусственный интеллект, нейросеть, рак прямой кишки.

КОНФЛИКТ ИНТЕРЕСОВ: авторы заявляют об отсутствии конфликта интересов.

ИСТОЧНИК ФИНАНСИРОВАНИЯ: субсидия Министерства Здравоохранения Российской Федерации

ДЛЯ ЦИТИРОВАНИЯ: Елигулашвили Р.Р., Зароднюк И.В., Ачкасов С.И., Белов Д.М., Михальченко В.А., Гончарова Е.П., Запольский А.Г., Сулова Д.И., Ряховская М.А., Никитин Е.Д., Филатов Н.С. Применение искусственного интеллекта в МРТ диагностике рака прямой кишки. *Колопроктология*. 2022; т. 21, № 1, с. 26–36. <https://doi.org/10.33878/2073-7556-2022-21-1-26-36>

The use of artificial intelligence in MRI diagnostics of rectal cancer

Revaz R. Eligulashvili¹, Irina V. Zarodnyuk¹, Sergei I. Achkasov¹, Denis M. Belov¹, Vera A. Mikhachenko¹, Elena P. Goncharova¹, Alexander G. Zapolskiy², Darya I. Suslova², Mariya A. Ryakhovskaya², Evgenii D. Nikitin³, Nikolay S. Filatov³

¹Ryzhikh National Medical Research Center of Coloproctology (Salyama Adilya str., 2, Moscow, 123423, Russia)

²JSC "National Center of Service Integration" (Berezhkovskaya embankment, 38, building 1, floor 3, room 1, Moscow, 121059, Russia)

³LLC "Medical Screening Systems" (Tsiolkovsky str., 4, office 301, Kaluga, 248000, Russia)

ABSTRACT AIM: to work out decision-making support systems for MRI diagnostics of rectal cancer: site and segmentation of the primary tumor.

PATIENTS AND METHODS: the study included 450 MRI studies of patients with rectal cancer and 450 MRI studies of patients without. All patients with tumors of rectum had histological verification. Data were collected in T2W coronal and axial projections (MRI Philips Achieva 1.5 T). Object marking was carried out only for T2W projections, where the area of interest was segmented — rectum, sigmoid colon and tumor. The ITK-Snap program was used to label MRI images. The validated studies and labeling were used to create a machine learning model that demonstrates the capability of the dataset to build medical decision support systems. SegResNet, TransUnet, 3D Unet neural networks were used to create a basic artificial intelligence model.

RESULTS: dice similarity coefficient (DSC) of various neural networks were: TransUnet — 0.33, SegResNet — 0.50, 3D Unet — 0.42. The diagnostic efficiency of the SegResNet neural network in detecting rectal tumors with the addition of negative examples and post-processing was accuracy 77.0%; sensitivity 98.1%; specificity 45.1%; positive predictive value 72.9%; negative predictive value of 94.1%. At this stage, AI has a high sensitivity and accuracy, which indicates a high diagnostic efficiency in terms of visualizing the primary tumor and determining localization in the rectum. However, the specificity of the method is still at an unsatisfactory level (45.1%), which indicates a high percentage of false positive results in healthy patients and does not allow the model to be used as a screening method at this stage of development.

CONCLUSION: the collected dataset of MRI and their markup made it possible to obtain an AI model that allows solving the problem of segmenting a rectal tumor and determining its site. The next stage in the development of AI is to improve its specificity, expand the analyzed parameters, such as the depth of tumor invasion, visualization of metastatic lymph nodes and the status of the resection margin. To further develop the model metric and improve its diagnostic capabilities, we should experiment with training parameters and increase the dataset.

KEYWORDS: MRI, magnetic resonance imaging, artificial intelligence, neural network, rectal cancer.

CONFLICT OF INTEREST: The authors declare no conflict of interest.

FINANCIAL INTERESTS: grant from the Ministry of Health of the Russian Federation.

FOR CITATION: Eligulashvili R.R., Zarodnyuk I.V., Achkasov S.I., Belov D.M., Mikhachenko V.A., Goncharova E.P., Zapolskiy A.G., Suslova D.I., Ryakhovskaya M.A., Nikitin E.D., Filatov N.S. The use of artificial intelligence in MRI diagnostics of rectal cancer. *Koloproktologia*. 2022;21(1):26–36. (in Russ.). <https://doi.org/10.33878/2073-7556-2022-21-1-26-36>

АДРЕС ДЛЯ ПЕРЕПИСКИ: Елигулашвили Р.Р., ФГБУ «НМИЦ колопроктологии имени А.Н. Рыжих» Минздрава России, ул. Салыма Адилья, д. 2, г. Москва, 123423, Россия; e-mail: info@gnck.ru

ADDRESS FOR CORRESPONDENCE: Eligulashvili R.R., Ryzhikh National Medical Research Center of Coloproctology, Salyama Adilya str., 2, Moscow, 123423, Russia; e-mail: info@gnck.ru

Дата поступления — 11.01.2022

Received — 11.01.2022

После доработки — 17.01.2022

Revised — 17.01.2022

Принято к публикации — 08.03.2022

Accepted for publication — 08.03.2022

ВВЕДЕНИЕ

Колоректальный рак (КРР) занимает ведущие позиции по показателям заболеваемости и смертности среди онкологических заболеваний как в Российской

Федерации, так и во всем мире. В нашей стране рак толстой кишки занимает второе место как по распространенности, так и по смертности среди всех злокачественных заболеваний. Приблизительно половина всех случаев злокачественных новообразований

толстой кишки приходится на рак прямой кишки (РПК) [1–3].

Комплексный подход в лечении больных раком прямой кишки с использованием хирургии, лучевой терапии и химиотерапии значительно увеличило безрецидивную выживаемость и улучшило качество их жизни. Точная предоперационная диагностика играет важную роль в выборе и определении вариантов лечения для пациентов со злокачественными новообразованиями прямой кишки [4]. Ошибки в диагностике приводят к несоответствию между планами предоперационного и послеоперационного лечения, что может негативно сказаться на прогнозе у пациентов, которые уже перенесли операцию [5]. На данный момент ведущим инструментальным методом диагностики и предоперационного стадирования рака прямой кишки является магнитно-резонансная томография (МРТ) малого таза, позволяющая определить локализацию, протяженность, глубину инвазии опухоли, оценить состояние регионарных лимфатических узлов [6,7].

Благодаря постоянному совершенствованию технологий визуализации и опыту врачей-рентгенологов точность предоперационной диагностики значительно повысилась. Однако высокая распространенность РПК, нехватка необходимого опыта рентгенологов в лечебно-профилактических учреждениях общего профиля для диагностики КРК, большие объемы данных МРТ-исследований, требующих детального анализа, в некоторых случаях приводят к постановке ошибочного диагноза. Таким образом, одной из главных задач является уменьшение количества ошибок в предоперационной диагностике [8]. Применение искусственного интеллекта для обработки и предварительного анализа данных медицинской визуализации, включая МРТ, становится одним из трендов современной медицины [9–11]. Искусственный интеллект (ИИ) обеспечивает стабильную диагностическую эффективность, высокую вычислительную скорость и точность при обработке данных. За счет использования методов глубокого обучения, ИИ может обеспечить высокую диагностическую точность, сопоставимую той, которую имеют врачи-рентгенологи, специализирующиеся на диагностике КРК. В настоящее время технология ИИ для анализа изображений уже нашла применение в клинической практике [12,13]. Применение искусственного интеллекта для интерпретации изображений может помочь в работе рентгенологов, не имеющих достаточного опыта в диагностике рака прямой кишки, повысить скорость анализа изображений, уменьшить количество ошибок, вызванных человеческим фактором, и повысить точность диагностики [8]. Ввиду сложности поставленной задачи, на первом

этапе разработки модели ИИ для анализа МРТ малого таза следует сфокусироваться на определении локализации и сегментации первичной опухоли, что в перспективе значительно сократит время анализа и интерпретации МР-изображений для рентгенологов, не имеющих большого клинического опыта в диагностике рака прямой кишки. В дальнейшем наиболее важными параметрами для оценки МРТ исследований с помощью ИИ будут являться определение глубины инвазии опухоли, визуализация метастатически измененных лимфатических узлов, оценка циркулярного края резекции.

ЦЕЛЬ ИССЛЕДОВАНИЯ

Разработка систем поддержки принятия врачебного решения при МРТ-диагностике рака прямой кишки: локализация и сегментация первичной опухоли.

ПАЦИЕНТЫ И МЕТОДЫ

Для обучения модели ИИ визуализировать на МРТ изображениях рак прямой кишки в исследование включено 450 пациентов с опухолями прямой кишки в возрасте от 26 до 82 лет, с гистологической верификацией «аденокарцинома». Пациенты без гистологической верификации злокачественной опухоли в исследование не включались. Всем пациентам с опухолями прямой кишки, вошедшим в исследование, выполнено предоперационное МРТ малого таза с использованием Т2-ВИ высокого разрешения (FOV = 180×180 мм; Voxel = 0,7×0,7 мм; Matrix = 256×256 мм). Далее всем пациентам было проведено радикальное хирургическое лечение, с последующим патоморфологическим исследованием операционных препаратов. Характеристика выборки пациентов с опухолями представлена ниже (Табл. 1).

Все МРТ-исследования выполнялись на высокопольной магнитно-резонансной системе Philips Achieva (Нидерланды) с напряженностью магнитного поля 1,5 Тл. Разметка выполнялась врачами-рентгенологами ФГБУ «НМИЦ колопроктологии имени А.Н. Рыжих» Минздрава России. Каждое исследование размечалось одним специалистом, однако, при неоднозначной МР-картине и сложностях в разметке привлекался второй специалист. Окончательная сегментация опухоли в таких случаях проводилась на основании консенсуса. Для разметки МРТ-изображений была использована программа ITK-Snap, с помощью которой была размечена соответствующая сегментационная маска первичной опухоли всем 450 пациентам [14]. Машинное обучение проводилось

Таблица 1. Характеристика больных раком прямой кишки
Table 1. Characteristics of patients with rectal cancer

	Пол		Т стадия				Химиолучевая терапия	
	муж	жен	T1	T2	T3	T4	Да	Нет
Пациенты с опухолью прямой кишки	214 (47,6%)	236 (52,4%)	33 (7,3%)	96 (21,4%)	279 (62,1%)	42 (9,2%)	209 (46,4%)	241 (53,6%)

с использованием разметки первичной опухоли на T2-ВИ высокого разрешения в аксиальной и коронарной проекциях (Рис. 1).
Также в объем данных для обучения искусственного интеллекта сегментации прямой кишки вошли 450

пациентов без опухолевого поражения прямой кишки, которым было выполнено МРТ малого таза с использованием протоколов высокого разрешения без дополнительной разметки. Анатомические области прямой кишки размечены для 120 пациентов в группе




Рисунок 1. МРТ малого таза, T2-ВИ коронарная проекция. А — опухоль прямой кишки без разметки. Б — опухоль прямой кишки с разметкой
Figure 1. MRI of the pelvis, T2-WI coronal view. A — tumor of the rectum without marking. Б — tumor of the rectum with markings




Рисунок 2. МРТ малого таза, T2-ВИ аксиальная проекция. А — прямая кишки без разметки. Б — прямая кишка с разметкой рентгенолога
Figure 2. MRI of the pelvis, T2-WI axial view. A — rectum without markings. Б — rectum with radiologist markings

с опухолями и для 48 пациентов без новообразований прямой кишки (Рис. 2).

Суммарно в объеме данных содержалось 1761 волюм Т2-ВИ. Баланс классов разметки по волюмам и слайсам представлен на рисунке 3.

Набор данных по волюмам был случайным образом разделен на обучающую, валидационную и тестовую выборки в соотношении 60%, 20%, 20% (Рис. 4).

Собранный набор данных являлся сбалансированным по количеству пациентов с опухолями и без.

В качестве базовой модели, служащей для демонстрации пригодности набора данных для решения поставленных задач, использована модифицированная нейросеть SegResNet с алгоритмами предобработки и постобработки данных (Рис. 5) [15].

Нейросеть SegResNet является трехмерной U-net — подобной архитектурой, в которой входной набор слайсов обрабатывается как набор трехмерных патчей по принципу скользящего окна. Подобные архитектуры хорошо заявили себя в обработке медицинских изображений, поскольку позволяют эффективно использовать трехмерный контекст при сегментации объектов [16]. При обучении этой модели выбран размер патча $256 \times 256 \times 16$ с перекрытием 0,5.

Поскольку размерность обрабатываемых волюмов в исходной реализации нейросети была меньше, то для более полного извлечения признаков в нейросеть был добавлен дополнительный сверточный слой в ветке — энкодере и дополнительный сверточный слой в ветке — декодере. Дополнительная



Рисунок 3. Баланс классов разметки по волюмам (А) и слайсам (Б)

Figure 3. Balance of markup classes by volumes (A) and slices (B)




Рисунок 4. Объем обучающей, валидационной и тестовой выборок

Figure 4. Volume of training, validation and test sets

ветка — автоэнкодер, введенная в архитектуру SegResNet для регуляризации, не использовалась. Общая схема работы базовой модели представлена на рисунке 6.

Предобработка состоит из нормализации интенсивностей входного вольюма, а также из разделения входного массива на трехмерные перекрывающиеся патчи размерности $256 \times 256 \times 16$. Под нормализацией интенсивностей (Рис. 7) в данном случае принималась операция вычитания среднего арифметического ненулевых

значений в массиве и деление на среднее квадратическое отклонение ненулевых элементов в массиве.

Во время сбора набора данных было проведено несколько экспериментов по сравнению качества работы различных нейронных сетей для решения поставленной задачи. Помимо выбранной архитектуры SegResNet обучались нейросети 3d UNet и TransUNet [17], также хорошо зарекомендовавшие себя в обработке медицинских изображений. Нейросеть TransUNet является двухмерной




Рисунок 5. Архитектура нейросети SegResNet

Figure 5. Architecture of SegResNet neural network



Рисунок 6. Общая схема работы базовой модели

Figure 6. General scheme of the basic model

$$\hat{X}_i(x, y, d) = \frac{x_i(x, y, d) - \mu}{\sqrt{\sigma^2}},$$

$\hat{X}_i(x, y, d)$ - нормализованное значение;

$x_i(x, y, d)$ - значение элемента массива с координатами x, y, d ;

$$\mu = \frac{1}{k} \sum_{i=1}^k x_i(x, y, d); x_i \neq 0$$

- математическое ожидание ненулевых элементов в массиве;

$$\sigma^2 = \frac{1}{k} \sum_{i=1}^k (x_i(x, y, d) - \mu_B(x, y, d))^2; x_i \neq 0$$

- среднее квадратическое отклонение ненулевых элементов в массиве.

Рисунок 7. Формула расчета нормализации интенсивностей входного вольюма

Figure 7. The formula for calculating the normalization of the intensities of the input volume

Таблица 2. Результаты обучения на выборке без отрицательных случаев
Table 2. Outcomes of training on the sample without negative cases

Архитектура	Количество параметров, $\times 10^6$	Коэффициент близости (DSC)	
		Опухоль	Прямая кишка
TransUnet	105	0,33	–
SegResNet	18	0,53	0,71
3D Unet	44	0,66	–

Таблица 3. Результаты обучения на расширенной выборке с добавлением отрицательных примеров
Table 3. Outcomes of training on an expanded sample with the addition of negative examples

Архитектура	Количество параметров, $\times 10^6$	Коэффициент близости (DSC)	
		Опухоль	Прямая кишка
TransUnet	105	0,33	–
SegResNet	18	0,50	0,71
3D Unet	44	0,42	–

в отличие от 3d UNet и SegResNet и выбрана для оценки важности использования трехмерного изображения при анализе МРТ малого таза. В проведенных экспериментах все нейросети обучались на одинаковых подмножествах набора данных и были использованы следующие аугментации: случайное кадрирование, случайное отражение по горизонтали, случайное отражение по вертикали, случайный сдвиг интенсивностей, случайное масштабирование.

РЕЗУЛЬТАТЫ

Первый эксперимент был проведен до добавления в набор данных случаев без опухоли прямой кишки и содержал 66 вольюмов с опухолями в обучающей выборке и 30 вольюмов в тестовой выборке. Полученные в результате обучения коэффициенты

близости (dice similarity coefficient (DSC)) представлены в таблице 2.

Из таблицы видно, что более высоким коэффициентом близости (DSC) обладают нейросети 3d UNet и SegResNet, имеющие трехмерную архитектуру.

После расширения набора данных и добавления случаев без рака был проведен анализ с включением 520 вольюмов в обучающую выборку и 178 вольюмов в тестовую выборку, после чего подсчитаны коэффициенты близости (DSC) (Табл. 3).

Анализируя данные из таблиц 2 и 3, видно, что с добавлением в выборку пациентов без опухолей прямой кишки коэффициент близости (DSC) снижается. Однако добавление отрицательных примеров в обучающий набор данных позволило обучить нейросеть разделять выборку пациентов на группу с опухолями прямой кишки и группу без патологических изменений. На рисунке 8 представлена матрица ошибок нейросети SegResNet, обученной на выборке без




Рисунок 8. Матрица ошибок SegResNet обученной без отрицательных примеров

Figure 8. Error matrix of SegResNet trained without negative examples



Рисунок 9. Матрица ошибок SegResNet с добавлением отрицательных примеров и постобработкой

Figure 9. Error Matrix of SegResNet with Added Negative Examples and Post-Processing

отрицательных примеров. На рисунке 9 представлена матрица ошибок для нейросети SegResNet, обученной на выборке с добавлением отрицательных примеров и добавлением постобработки предсказаний.

Можно предположить, что коэффициент близости (DSC) в смешанной выборке пациентов снижается, в связи с ложноположительными результатами на пациентах без РПК.

Диагностическая эффективность нейросети SegResNet в выявлении опухолей прямой кишки с добавлением отрицательных примеров и постобработкой составила: точность — 77,0%; чувствительность — 98,1%; специфичность — 45,1%; положительная прогностическая ценность — 72,9%; отрицательная прогностическая ценность — 94,1%. Таким образом, показано, что добавление пациентов без опухолей в обучающую выборку необходимо, несмотря на то, что в случаях с РПК содержится большее количество слайсов здоровой прямой кишки. Полученная точность классификации демонстрирует, что из добавленных данных возможно обучить нейросеть разделять общую выборку на две группы пациентов.

Визуальный анализ разметки опухоли показал, что для опухоли коэффициент DSC также снижается из-за не идеального предварительного оконтуривания. Однако визуальная разметка опухоли нейросетью имеет хорошую сходимость с предварительной аннотацией, проведенной врачами-рентгенологами с большим клиническим опытом (Рис. 10).

ОБСУЖДЕНИЕ

Своевременная и точная диагностика опухолей прямой кишки позволяет применять органосохраняющее лечение, уменьшить объем радикального оперативного лечения, улучшить прогноз жизни пациента

и повысить ее качество. Магнитно-резонансная томография является высокоинформативным методом диагностики и стадирования рака прямой кишки [6,7,18]. Информация, полученная при МРТ-исследованиях органов малого таза, позволяет определить тактику лечения пациентов с РПК [19]. Специалистам лучевой диагностики при анализе МРТ-исследований органов малого таза необходимо оценить большой объем информации, визуализировать первичную опухоль и оценить ее распространенность. Недостаточный опыт рентгенологов в лечебно-профилактических учреждениях общей практики в интерпретации МР-исследований рака прямой кишки может привести к ошибкам в диагностике, значительным временным затратам на анализ полученных МР-изображений и субъективизму в оценке распространенности опухолевого процесса.

В настоящее время, с быстрым развитием передовых технологий, искусственный интеллект используется во многих областях. Искусственный интеллект на основе нейронных сетей все чаще используется в медицине для сбора и анализа больших объемов информации, способствующих более эффективной работе врачей [20]. Использование автоматизации обработки изображений с использованием ИИ при анализе МРТ таза у больных раком прямой кишки призвано сократить время описания исследования, в перспективе повысить диагностическую точность метода и нивелировать субъективизм врача-рентгенолога. Применение ИИ в диагностике рака прямой кишки только начинает изучаться, проведены единичные научные исследования на небольшой выборке пациентов [21,22].

В нашем исследовании мы использовали технологию искусственного интеллекта, основанную на нейросетях, для автоматического поиска и сегментации опухолей прямой кишки.




Рисунок 10. МРТ малого таза, T2-ВИ коронарная проекция. А — опухоль прямой кишки без разметки. Б — опухоль прямой кишки с разметкой рентгенолога. В — опухоль прямой кишки с разметкой нейросети SegResNet

Figure 10. MRI of the pelvis, T2-WI coronal view. A — tumor of the rectum without marking. Б — a tumor of the rectum with the markings of a radiologist. В — tumor of the rectum with the markings of SegResNet neural network

В начале на исследованиях с первичной опухолью были определены коэффициенты близости (DSC) для различных типов нейросетей: TransUnet — 0,33, SegResNet — 0,53, 3D Unet — 0,66. Более высоким коэффициентом близости обладают нейросети 3D Unet и SegResNet, имеющие трехмерную архитектуру. МРТ позволяет визуализировать опухоль в трехмерном пространстве в любой выбранной проекции, что объясняет целесообразность использования 3D нейронных сетей.

После увеличения выборки и добавления пациентов без опухолей прямой кишки были повторно определены коэффициенты близости (DSC): TransUnet — 0,33, SegResNet — 0,50, 3D Unet — 0,42. Коэффициент близости (DSC) в смешанной выборке пациентов ниже, чем в группе только с опухолями, в связи с ложноположительными результатами на пациентах без рака. Однако добавление здоровых пациентов в группу сравнения необходимо для обучения нейросети дифференцировать опухоль и неизмененную стенку прямой кишки.

Диагностическая эффективность нейросети SegResNet в выявлении опухолей прямой кишки с добавлением отрицательных примеров и постобработкой составила: точность — 77,0%; чувствительность — 98,1%; специфичность — 45,1%; положительная прогностическая ценность — 72,9%; отрицательная прогностическая ценность — 94,1%. На данном этапе ИИ обладает довольно высокой чувствительностью, что говорит о высокой диагностической эффективности в отношении визуализации первичной опухоли. Однако специфичность метода в 45,1% пока на неудовлетворительном уровне, что говорит о высоком проценте ложноположительных результатов у здоровых пациентов.

Разработанная базовая модель ИИ имеет удовлетворительные показатели диагностической эффективности для столь сложной клинической задачи и в перспективе может быть использована в качестве помощи рентгенологу для повышения скорости поиска первичной опухоли прямой кишки и для сокращения ошибок в определении ее локализации. Однако модель на данном этапе не может применяться в качестве скринингового метода, ввиду большого количества ложноположительных случаев среди здоровых пациентов. Полученные результаты являются отправной точкой нашего исследования, и при целенаправленной разработке нейросетей для решаемой задачи возможен значительный прирост диагностической эффективности метода. Следующим этапом развития ИИ будет являться улучшение ее специфичности, расширение анализируемых параметров, таких как глубина инвазии опухоли, визуализация метастатических лимфатических узлов и определение статуса края резекции.

ЗАКЛЮЧЕНИЕ

Собранный датасет МРТ-исследований и их разметка, позволили получить ИИ-модель, которая позволяет решать задачу сегментирования опухоли прямой кишки и определение ее локализации. Нейросеть SegResNet имеет приемлемый коэффициент близости (DSC = 0,55), а визуальный анализ подтвердил высокую сходимость сегментации опухоли рентгенологом и моделью ИИ. Диагностическая эффективность нейросети SegResNet в выявлении опухолей прямой кишки: точность — 77,0%; чувствительность — 98,1%; специфичность — 45,1%; положительная прогностическая ценность — 72,9%; отрицательная прогностическая ценность — 94,1%. Для дальнейшей разработки метрики модели и улучшения ее диагностических возможностей, следует экспериментировать с параметрами обучения и увеличивать набор данных.

УЧАСТИЕ АВТОРОВ

Концепция и дизайн: *Елигулашвили Р.Р., Зароднюк И.В., Ачкасов С.И., Запольский А.Г.*

Сбор и обработка материала: *Елигулашвили Р.Р., Белов Д.М., Михальченко В.А., Гончарова Е.П., Суслова Д.И., Ряховская М.А., Никитин Е.Д., Филатов Н.С.*

Написание текста: *Елигулашвили Р.Р., Зароднюк И.В.*

Редактирование текста: *Зароднюк И.В., Ачкасов С.И.*

AUTHORS CONTRIBUTION

Concept and design of the study: *Revaz R. Eligulashvili, Irina V. Zarodnyuk, Sergei I. Achkasov, Alexander G. Zapolskiy.*

Processing of the material: *Revaz R. Eligulashvili, Denis M. Belov, Vera A. Mikhalchenko, Elena P. Goncharova, Darya I. Suslova, Mariya A. Ryakhovskaya, Evgeniy D. Nikitin, Nikolaiy S. Filatov*

Writing of the text: *Revaz R. Eligulashvili, Irina V. Zarodnyuk*

Editing: *Irina V. Zarodnyuk, Sergei I. Achkasov*

СВЕДЕНИЯ ОБ АВТОРАХ (ORCID)

Елигулашвили Р.Р. — 0000-0001-9885-6824

Зароднюк И.В. — 0000-0002-9442-7480

Ачкасов С.И. — 0000-0001-9294-5447

Белов Д.М. — 0000-0003-2545-7966

Михальченко В.А. — 0000-0002-0577-0528

Гончарова Е.П. — 0000-0001-6785-5191

Запольский А.Г. — 0000-0002-4964-0848

Суслова Д.И. — 0000-0003-1106-5486

Ряховская М.А. — 0000-0002-2243-1317

Никитин Е.Д. — 0000-0001-7181-1036

Филатов Н.С. — 0000-0002-0657-1256

INFORMATION ABOUT AUTHORS (ORCID)

Revaz R. Eligulashvili — 0000-0001-9885-6824
 Irina V. Zarodnyuk — 0000-0002-9442-7480
 Sergei I. Achkasov — 0000-0001-9294-5447
 Denis M. Belov — 0000-0003-2545-7966
 Vera A. Mikhilchenko — 0000-0002-0577-0528

Elena P. Goncharova — 0000-0001-6785-5191
 Alexander G. Zapolskiy — 0000-0002-4964-0848
 Darya I. Suslova — 0000-0003-1106-5486
 Mariya A. Ryakhovskaya — 0000-0002-2243-1317
 Evgeniy D. Nikitin — 0000-0001-7181-1036
 Nikolai S. Filatov — 0000-0002-0657-1256

ЛИТЕРАТУРА

- Каприн А.Д., Старинский В.В., Шахзадова А.О. Злокачественные новообразования в России в 2019 году (заболеваемость и смертность). М.: МНИОИ им. П.А. Герцена (филиал ФГБУ «НМИЦ» Минздрава России). 2020;252 с.
- Ferlay J, Soerjomataram I, Dikshit R. et al. Cancer incidence and mortality worldwide: Sources, methods and major patterns in GLOBOCAN 2012. *Int J Cancer*. 2015;136:E359–E386. DOI: 10.1002/ijc.29210
- Каприн А.Д., Старинский В.В., Шахзадова А.О. Состояние онкологической помощи населению России в 2019 году. М.: МНИОИ им. П.А. Герцена (филиал ФГБУ «ФМИЦ им. П.А. Герцена» Минздрава России). 2020; 239 с.
- Wang H, Fu C. Value of preoperative accurate staging of rectal cancer and the effect on the treatment strategy choice (in Chinese). *Chin J Pract Surg*. 2014;34:37–40. DOI: 10.3969/j.issn.1674-9316.2016.02.058
- Abraha I, Aristei C, Palumbo I, et al. Preoperative radiotherapy and curative surgery for the management of localised rectal carcinoma. *Cochrane Database Syst Rev*. 2018;10(10):CD002102. DOI: 10.1002/14651858.CD002102.pub3
- Jhaveri KS, Sadaf A. Role of MRI for staging of rectal cancer. *Expert Rev Anticancer Ther*. 2009;9(4):469–481. DOI: 10.1586/era.09.13
- Beets-Tan R, Lambregts D, Maas M, et al. Magnetic resonance imaging for clinical management of rectal cancer: Updated recommendations from the 2016 European Society of Gastrointestinal and Abdominal Radiology (ESGAR) consensus meeting [published correction appears in *Eur Radiol*. 2018;28(4):1465–1475. DOI: 10.1007/s00330-017-5026-2
- Xiao Y, Liu S. Artificial intelligence will change the future of imaging medicine (in Chinese). *J Technol Finance*. 2018;10:11–15. DOI: 10.3969/j.issn.2096-4935.2018.10.006
- Wang Y, He X, Nie H, et al. Application of artificial intelligence to the diagnosis and therapy of colorectal cancer. *Am J Cancer Res*. 2020;10(11):3575–3598.
- Perone C, Cohen-Adad J. Promises and limitations of deep learning for medical image segmentation. *J Med Artif Intel*. 2019;2:1–2. DOI: 10.21037/jmai.2019.01.01
- Ding L, Liu G, Zhao B. et al. Artificial intelligence system of faster region-based convolutional neural network surpassing senior radiologists in evaluation of metastatic lymph nodes of rectal cancer. *Chin Med J*. 2019;132(4):379–87. DOI: 10.1097/CM9.000000000000095
- Harangi B. Skin lesion classification with ensembles of deep

- convolutional neural networks. *J Biomed Inform*. 2018;86:25–32. DOI: 10.1016/j.jbi.2018.08.006
- Ehteshami Bejnordi B, Veta M, Johannes van Diest P, et al. Diagnostic Assessment of Deep Learning Algorithms for Detection of Lymph Node Metastases in Women With Breast Cancer. *JAMA*. 2017;318(22):2199–2210. DOI: 10.1001/jama.2017.14585
- Yushkevich PA, Piven J, Hazlett HC, et al. User-guided 3D active contour segmentation of anatomical structures: significantly improved efficiency and reliability. *Neuroimage*. 2006;31(3):1116–1128. DOI: 10.1016/j.neuroimage.2006.01.015
- Baid U, Chodasara S, Mohan S, et al. The rsna-asnr-miccai brats 2021 benchmark on brain tumor segmentation and radiogenomic classification. *arXiv*. 2021;2107.02314.
- Magadza T, Viriri S. Deep Learning for Brain Tumor Segmentation: A Survey of State-of-the-Art. *J Imaging*. 2021;7(2):19. DOI: 10.3390/jimaging7020019
- Balakrishnan G, Zhao A, Sabuncu M. et al. VoxelMorph: A Learning Framework for Deformable Medical Image Registration. *IEEE Transactions on Medical Imaging*. 2019;38(8):1788–1800 DOI: 10.1109/TMI.2019.2897538
- Taylor F, Quirke P, Heald RJ, et al. Preoperative high-resolution magnetic resonance imaging can identify good prognosis stage I, II, and III rectal cancer best managed by surgery alone: a prospective, multicenter, European study. *Ann Surg*. 2011;253(4):711–719. DOI: 10.1097/SLA.0b013e31820b8d52.
- Чернышов С.В., Хомяков Е.А., Сеницын Р.К. и соавт. Скрытая аденокарцинома в аденомах. Возможности инструментальной идентификации. *Коллопроктология*. 2021;20(2):10–17. DOI: 10.33878/2073-7556-2021-20-2-10-16
- Thrall J, Li X, Li Q. et al. Artificial Intelligence and Machine Learning in Radiology: Opportunities, Challenges, Pitfalls, and Criteria for Success. *J Am Coll Radiol*. 2018;15:504–508. DOI: 10.1016/j.jacr.2017.12.026
- Wu QY, Liu SL, Sun P. et al. Establishment and clinical application value of an automatic diagnosis platform for rectal cancer T-staging based on a deep neural network. *Chin Med J (Engl)*. 2021;134(7):821–828. DOI: 10.1097/CM9.0000000000001401
- Lu Y, Yu Q, Gao Y. et al. Identification of Metastatic Lymph Nodes in MR Imaging with Faster Region-Based Convolutional Neural Networks. *Cancer Res*. 2018;78(17):5135–5143. DOI: 10.1158/0008-5472.CAN-18-0494

REFERENCES

- Kaprin A.D., Starinsky V.V., Shahzadova A.O. Malignant neoplasms in Russia in 2019 (morbidity and mortality). Moscow: MNI OI. P.A. Herzen (branch FGBU “MICR” of Minzdrav of Russia). 2020; p. 252. (in Russ.).
- Ferlay J, Soerjomataram I, Dikshit R, et al. Cancer incidence and mortality worldwide: Sources, methods and major patterns in GLOBOCAN 2012. *Int J Cancer*. 2015;136:E359–E386. DOI: 10.1002/ijc.29210
- Kaprin A.D., Starinsky V.V., Shakhzadova A.O. The state of onco-

- logical care for the population of Russia in 2019. Moscow: MNI OI. P.A. Herzen (branch FGBU “MICR” of Minzdrav of Russia). 2020; p. 239 (in Russ.).
- Wang H, Fu C. Value of preoperative accurate staging of rectal cancer and the effect on the treatment strategy choice (in Chinese). *Chin J Pract Surg*. 2014;34:37–40. DOI: 10.3969/j.issn.1674-9316.2016.02.058
- Abraha I, Aristei C, Palumbo I, et al. Preoperative radiotherapy and curative surgery for the management of localised rectal

- carcinoma. *Cochrane Database Syst Rev.* 2018;10(10):CD002102. DOI: 10.1002/14651858.CD002102.pub3
6. Jhaveri KS, Sadaf A. Role of MRI for staging of rectal cancer. *Expert Rev Anticancer Ther.* 2009;9(4):469–481. DOI: 10.1586/era.09.13
 7. Beets-Tan R, Lambregts D, Maas M, et al. Magnetic resonance imaging for clinical management of rectal cancer: Updated recommendations from the 2016 European Society of Gastrointestinal and Abdominal Radiology (ESGAR) consensus meeting [published correction appears in *Eur Radiol.* *Eur Radiol.* 2018;28(4):1465–1475. DOI: 10.1007/s00330-017-5026-2
 8. Xiao Y, Liu S. Artificial intelligence will change the future of imaging medicine (in Chinese). *J Technol Finance.* 2018;10:11–15. DOI: 10.3969/j.issn.2096-4935.2018.10.006
 9. Wang Y, He X, Nie H, et al. Application of artificial intelligence to the diagnosis and therapy of colorectal cancer. *Am J Cancer Res.* 2020;10(11):3575–3598.
 10. Perone C, Cohen-Adad J. Promises and limitations of deep learning for medical image segmentation. *J Med Artif Intel.* 2019;2:1–2. DOI: 10.21037/jmai.2019.01.01
 11. Ding L, Liu G, Zhao B, et al. Artificial intelligence system of faster region-based convolutional neural network surpassing senior radiologists in evaluation of metastatic lymph nodes of rectal cancer. *Chin Med J.* 2019;132(4):379–87. DOI: 10.1097/CM9.000000000000095
 12. Harangi B. Skin lesion classification with ensembles of deep convolutional neural networks. *J Biomed Inform.* 2018;86:25–32. DOI: 10.1016/j.jbi.2018.08.006
 13. Ehteshami Bejnordi B, Veta M, Johannes van Diest P, et al. Diagnostic Assessment of Deep Learning Algorithms for Detection of Lymph Node Metastases in Women With Breast Cancer. *JAMA.* 2017;318(22):2199–2210. DOI: 10.1001/jama.2017.14585
 14. Yushkevich PA, Piven J, Hazlett HC, et al. User-guided 3D active contour segmentation of anatomical structures: significantly improved efficiency and reliability. *Neuroimage.* 2006;31(3):1116–1128. DOI: 10.1016/j.neuroimage.2006.01.015
 15. Baid U, Chodasara S, Mohan S, et al. The rsna-asnr-miccai brats 2021 benchmark on brain tumor segmentation and radiogenomic classification. *arXiv.* 2021;2107.02314.
 16. Magadza T, Viriri S. Deep Learning for Brain Tumor Segmentation: A Survey of State-of-the-Art. *J Imaging.* 2021;7(2):19. DOI: 10.3390/jimaging7020019
 17. Balakrishnan G, Zhao A, Sabuncu M, et al. VoxelMorph: A Learning Framework for Deformable Medical Image Registration. *IEEE Transactions on Medical Imaging.* 2019;38(8):1788–1800 DOI: 10.1109/TMI.2019.2897538
 18. Taylor F, Quirke P, Heald RJ, et al. Preoperative high-resolution magnetic resonance imaging can identify good prognosis stage I, II, and III rectal cancer best managed by surgery alone: a prospective, multicenter, European study. *Ann Surg.* 2011;253(4):711–719. DOI: 10.1097/SLA.0b013e31820b8d52.
 19. Chernyshov S.V., Khomyakov E.A., Sinitsyn R.K. et al. Latent adenocarcinoma in adenomas. Possibilities of instrumental identification. *Koloproktologia.* 2021;20(2):10–17. (in Russ.). DOI: 10.33878/2073-7556-2021-20-2-10-16.
 20. Thrall J, Li X, Li Q. et al. Artificial Intelligence and Machine Learning in Radiology: Opportunities, Challenges, Pitfalls, and Criteria for Success. *J Am Coll Radiol.* 2018;15:504–508. DOI: 10.1016/j.jacr.2017.12.026
 21. Wu QY, Liu SL, Sun P. et al. Establishment and clinical application value of an automatic diagnosis platform for rectal cancer T-staging based on a deep neural network. *Chin Med J (Engl).* 2021;134(7):821–828. DOI: 10.1097/CM9.0000000000001401
 22. Lu Y, Yu Q, Gao Y. et al. Identification of Metastatic Lymph Nodes in MR Imaging with Faster Region-Based Convolutional Neural Networks. *Cancer Res.* 2018;78(17):5135–5143. DOI: 10.1158/0008-5472.CAN-18-0494