

doi: 10.17586/2226-1494-2024-24-1-124-132

УДК 004.891

Сегментация мышечной ткани на снимках компьютерной томографии на уровне позвонка L3

Анастасия Романовна Теплякова¹✉, Роман Владимирович Шершнев²,
Сергей Олегович Старков³, Татев Артаковна Агабабян⁴,
Валерия Андреевна Кукарская⁵

^{1,2,3} Обнинский институт атомной энергетики — филиал федерального государственного автономного образовательного учреждения высшего образования «Национальный исследовательский ядерный университет «МИФИ» (ИАТЭ НИЯУ МИФИ), Обнинск, 249039, Российская Федерация

^{4,5} Медицинский радиологический научный центр им. А.Ф. Цыба — филиал ФГБУ «Национальный медицинский исследовательский центр радиологии» Минздрава России, Обнинск, 249036, Российская Федерация

¹ anastasija-t23@mail.ru✉, <https://orcid.org/0000-0001-8612-3850>

² rvshershnev@yandex.ru, <https://orcid.org/0009-0000-2324-5893>

³ sergeystarkov56@mail.ru, <https://orcid.org/0000-0002-0420-7856>

⁴ tatevik.05@mail.ru, <https://orcid.org/0000-0002-9971-3451>

⁵ kukarely@mail.ru, <https://orcid.org/0009-0001-4872-3182>

Аннотация

Введение. С возрастающей рутинной нагрузкой на врачей-рентгенологов, связанной с необходимостью анализировать большое количество снимков, возникает потребность в автоматизации части процесса анализа. Саркопения представляет собой состояние, при котором происходит потеря мышечной массы. Для диагностики саркопении наиболее часто применяется компьютерная томография, по снимкам которой может быть оценен объем мышечной ткани. Первым этапом анализа является ее оконтуривание, которое выполняется вручную, занимает продолжительное время и не всегда производится достаточно качественно, что оказывает влияние на точность оценок и, как следствие, на план лечения пациента. Предметом исследования является применение подходов компьютерного зрения для точной сегментации мышечной ткани по снимкам компьютерной томографии с целью саркометрии. Цель исследования — разработка подхода к решению задачи сегментации собранных и размеченных снимков. **Метод.** Представленный подход включает в себя этапы предварительной обработки снимков, сегментации при помощи нейронных сетей семейства U-Net и постобработки. Всего рассмотрено 63 различных конфигурации подхода, которые отличаются с точки зрения данных, подаваемых на вход моделей, и архитектур моделей. Оценено влияние предложенного способа постобработки получаемых бинарных масок на точность сегментации. **Основные результаты.** Для конфигурации подхода, включающей предварительную обработку с маскированием стола томографа и применением анизотропной диффузионной фильтрации, сегментацию моделью, имеющей архитектуру Inception U-Net и постобработку на базе анализа контуров, получен коэффициент схожести Дайса (Dice similarity coefficient, DSC) 0,9379 и пересечение над объединением (Intersection over Union, IoU) — 0,8824. Девять из исследованных в работе конфигураций также продемонстрировали высокие значения метрик DSC (в диапазоне 0,9356–0,9374) и IoU (0,8794–0,8822). Предлагаемый подход на базе предобработанных трехканальных изображений позволяет достигать значений 0,9364 для DSC и 0,8802 для IoU с применением легковесной модели сегментации U-Net. В соответствии с описанным подходом реализован программный модуль на языке Python. **Обсуждение.** Результаты исследования подтверждают целесообразность применения компьютерного зрения для оценки показателей мышечной ткани. Разработанный модуль может применяться для снижения рутинной нагрузки на рентгенологов.

Ключевые слова

компьютерное зрение, сегментация, компьютерная томография, мышечная ткань, индекс скелетной мускулатуры, саркопения, диагностика

Ссылка для цитирования: Теплякова А.Р., Шершнев Р.В., Старков С.О., Агабабян Т.А., Кукарская В.А. Сегментация мышечной ткани на снимках компьютерной томографии на уровне позвонка L3 // Научно-технический вестник информационных технологий, механики и оптики. 2024. Т. 24, № 1. С. 124–132. doi: 10.17586/2226-1494-2024-24-1-124-132

© Теплякова А.Р., Шершнев Р.В., Старков С.О., Агабабян Т.А., Кукарская В.А., 2024

Segmentation of muscle tissue in computed tomography images at the level of the L3 vertebra

Anastasia R. Teplyakova¹✉, Roman V. Shershnev², Sergey O. Starkov³, Tatev A. Agababian⁴, Valeria A. Kukarskaya⁵

^{1,2,3} Obninsk Institute for Nuclear Power Engineering, Obninsk, 249039, Russian Federation

^{4,5} A. Tsyb Medical Radiological Research Centre – branch of the National Medical Research Radiological Center of the Ministry of Health of the Russia, Obninsk, 249036, Russian Federation

¹ anastasija-t23@mail.ru✉, <https://orcid.org/0000-0001-8612-3850>

² rvshershnev@yandex.ru, <https://orcid.org/0009-0000-2324-5893>

³ sergeystarkov56@mail.ru, <https://orcid.org/0000-0002-0420-7856>

⁴ tatevik.05@mail.ru, <https://orcid.org/0000-0002-9971-3451>

⁵ kukarely@mail.ru, <https://orcid.org/0009-0001-4872-3182>

Abstract

With the increasing routine workload on radiologists associated with the need to analyze large numbers of images, there is a need to automate part of the analysis process. Sarcopenia is a condition in which there is a loss of muscle mass. To diagnose sarcopenia, computed tomography is most often used, from the images of which the volume of muscle tissue can be assessed. The first stage of the analysis is its contouring, which is performed manually, takes a long time and is not always performed with sufficient quality affecting the accuracy of estimates and, as a result, the patient's treatment plan. The subject of the study is the use of computer vision approaches for accurate segmentation of muscle tissue from computed tomography images for the purpose of sarcometry. The purpose of the study is to develop an approach to solving the problem of segmentation of collected and annotated images. An approach is presented that includes the stages of image pre-processing, segmentation using neural networks of the U-Net family, and post-processing. In total, 63 different configurations of the approach are considered, which differ in terms of data supplied to the input models and model architectures. The influence of the proposed method of post-processing on the resulting binary masks on the segmentation accuracy is also evaluated. The approach, which includes pre-processing with table masking and anisotropic diffusion filtering, segmentation with an Inception U-Net architecture model, and post-processing based on contour analysis, achieves a Dice similarity coefficient of 0.9379 and Intersection over Union of 0.8824. Nine other configurations, the experimental results for which are reflected in the article, also demonstrated high values of these metrics (in the ranges of 0.9356–0.9374 and 0.8794–0.8822, respectively). The approach proposed in the article based on preprocessed three-channel images allows us to achieve metrics of 0.9364 and 0.8802, respectively, using the lightweight U-Net segmentation model. In accordance with the described approach, a software module was implemented in Python. The results of the study confirm the feasibility of using computer vision to assess muscle tissue parameters. The developed module can be used to reduce the routine workload on radiologists.

Keywords

computer vision, segmentation, computed tomography, muscle tissue, skeletal muscle index, sarcopenia, diagnostics

For citation: Teplyakova A.R., Shershnev R.V., Starkov S.O., Agababian T.A., Kukarskaya V.A. Segmentation of muscle tissue in computed tomography images at the level of the L3 vertebra. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*, 2024, vol. 24, no. 1, pp. 124–132 (in Russian). doi: 10.17586/2226-1494-2024-24-1-124-132

Введение

Саркопения имеет большую значимость в прогнозировании онкологических заболеваний [1]. В последние годы растет количество источников, подтверждающих тот факт, что оценка мышечной массы и определение вероятности развития саркопении у пациента при помощи рентгенологических методов позволяют получить эффективные биомаркеры. На сегодняшний день компьютерная томография (КТ) — не только точный и удобный с практической точки зрения метод оценки структуры тела, но и обязательная составная часть плановых исследований для диагностики, стадирования, наблюдения и оценки ответа на терапию у больных с опухолями [2, 3]. Однако в силу своего главного недостатка, заключающегося в дозовой нагрузке на пациента, КТ не может служить инструментом для оценки мышечной массы по результатам сканирования тела полностью. В связи с этим возникает необходимость применения подходов, позволяющих оценивать скелетно-мышечный индекс по аксиальному срезу КТ на определенном уровне. В [4–6] показано, что измеренная

при КТ площадь мышечной и жировой ткани на уровне третьего поясничного позвонка (L3) надежно коррелирует с объемом скелетной мускулатуры и жировой клетчатки всего тела у здоровых людей.

Обзор существующих подходов

В рамках исследования выполнен анализ ряда научных работ, посвященных подходам к диагностике саркопении по снимкам КТ. В работе [7], опубликованной Научно-практическим клиническим центром диагностики и телемедицинских технологий Департамента здравоохранения города Москвы, представлен обзор современных подходов к диагностике саркопении. Авторы подчеркивают перспективность исследований, направленных на создание программного обеспечения для оценки мышечной ткани. Рассмотрены две группы существующих методов сегментации (на базе поиска мышечной ткани по плотности в диапазонах, задаваемых в единицах Хаунсфилда (Hounsfield units, HU), и на базе применения машинного обучения). Предложен метод решения задачи через применение сети U-Net++

на обучающей выборке 15 пациентов. В результате получено значение коэффициента схожести Дайса (Dice similarity coefficient, DSC) — 0,9312. Применение сети с более сложной архитектурой помогло решить проблему, связанную с малым объемом выборки, однако привело к значительному увеличению вычислительных затрат на этапах обучения сети и предсказания в рамках клинического использования.

В работе [8] предложено применение архитектуры U-Net. Для обучения использован набор данных, включающий размеченные вручную снимки 102 уникальных пациентов. Усредненное значение DSC для всех сегментируемых в исследовании групп мышц составило $0,930 \pm 0,049$. На предлагаемых в работе [9] (в ней применен описанный в [8] алгоритм) снимках с демонстрацией работы алгоритма заметны артефакты сегментации, лежащие вне зоны интереса, что обусловлено отсутствием постобработки получаемых масок. В [10] реализована сегментация мышечной ткани при помощи ансамбля из 15 моделей глубокого обучения с архитектурой U-Net с 4-уровневой глубиной и 18 начальными фильтрами. Использовано 1025 отдельных срезов КТ на уровне позвонка L3 (для обучения и валидации) и 500 дополнительных срезов — для тестирования. Полученное среднее значение DSC равно 0,97. В работе [11] предложен подход к сегментации мышц и жировой ткани по снимкам КТ на уровне позвонка L3 у пациентов с политравмой, в качестве архитектуры выбрана U-Net, модель обучена на снимках 3413 пациентов. Получено среднее значение DSC для мышечной ткани — 0,926. Недостаток данного подхода — отсутствие предварительной обработки, из-за которого в масках сегментации присутствуют руки пациентов (авторы исследования выделили это для будущей работы). В [12] при помощи U-Net сегментированы отдельные группы мышц. Для обучения использованы снимки 130 пациентов, удаление артефактов реализовано за счет исключения пикселей со значениями, выходящими за рамки интервала от -20 до 200 HU. Для отдельных групп мышц получены значения DSC в диапазоне 0,86–0,95, для общей мышечной массы — 0,95. В работе [13] акцент сделан на сегментации отдельных групп мышц в случаях с цирротической саркопенией. Для решения задачи применена архитектура 2,5D U-Net в сочетании с ветвью 3D-кодирования. Набор данных содержит снимки 317 пациентов (из них 216 с циррозом печени). Достигнуто среднее значение DSC равное 0,937. Метод, описанный в работе [14], основан на сегментации при помощи полностью сверточной нейронной сети (Fully Convolutional Network, FCN). Для обучения использовано три набора данных, включающих в себя 6651 снимок КТ на уровне позвонка L3, достигнуто значение DSC — 0,9811. В [15] описано создание системы, состоящей из модулей сегментации мышечной и жировой тканей, их количественной оценки и анализа саркопении. В рамках обучения и тестирования моделей сегментации собраны и размечены снимки КТ 67 пациентов, проведены эксперименты с архитектурами Attention U-Net, U-Net и SegNet. Attention U-Net продемонстрировала самое высокое значение DSC для мышечной ткани равное 0,96. Преимуществом работы

является нацеленность на применение системы в клинической практике, учет времени обработки модулями исследования отдельного пациента (на сегментацию снимка затрачивается порядка 6 с). В [16] предложен полностью автоматизированный подход, который не только реализует сегментацию снимка КТ на уровне позвонка L3, но и обнаруживает его в массиве снимков исследования КТ пациента. Сегментация реализована обученной на 1070 снимках КТ FCN, основанной на U-Net-подобной архитектуре. DSC для отдельных групп мышц достигают значений в диапазоне 0,94–0,97, для объединенной мышечной массы — 0,96, заявленное время обработки одного исследования — 1 с.

Главные достоинства рассмотренных работ заключаются в том, что данные для исследований собраны в медицинских центрах и размечены квалифицированными рентгенологами, а также в том, что результаты востребованы и протестированы в условиях клинической практики. Однако в большинстве исследований мало внимания уделено технической реализации решений: предварительной обработке снимков, сравнению различных архитектур, методам постобработки масок сегментации. Программные части и наборы данных, полученные в рассмотренных зарубежных исследованиях, являются закрытыми, что влечет за собой невозможность применения результатов в клинической практике и доработки функционала под запросы специалистов-рентгенологов. Стоит также отметить отсутствие готового программного обеспечения для точной сегментации мышечной ткани по снимкам КТ на уровне позвонка L3 на российском рынке. В связи с этим возникла потребность в реализации собственного программного обеспечения, один из модулей которого может решать указанную задачу.

Преимущество предлагаемого в настоящей работе подхода заключается в реализации большого количества способов решения задачи: представлены результаты 63 различных модификаций подхода, для каждого из которых обучена своя модель. Варьируются 9 типов входных данных модели (в зависимости от применяемого алгоритма предварительной обработки снимков) и 7 архитектур сегментации (U-Net, Attention U-Net, U-Net++, ResU-Net, Inception U-Net, Dense U-Net, U²-Net). Для каждой из конфигураций выполнено сравнение метрик до и после применения алгоритма постобработки масок сегментации. Отметим, что предложен новый подход к обработке входных снимков, позволяющий повысить производительность самой легковесной из перечисленных архитектур (U-Net) до уровня производительности более сложных из них.

Постановка задачи

При проведении анализа состава тела пациента врач-рентгенолог выполняет количественную оценку мышц по снимкам КТ брюшной полости. Для этого он вручную осуществляет разметку мышечной ткани на снимке, соответствующем уровню позвонка L3. Разметка снимка КТ представляет собой формирование маски сегментации, основанной на точках контуров (каждая наносится нажатием кнопки компьютерной

мыши) мышечной ткани, и занимает порядка 5,5 мин без использования предварительной разметки, выдаваемой полуавтоматическими программными средствами (с нуля), и порядка 2,8 мин — с ее использованием [17]. Задача заключается в разработке программного модуля, получающего на вход DICOM файл со снимком КТ на уровне позвонка L3 и возвращающего его в обработанном виде (с оверлеем, содержащим контуры мышечной ткани). Задача включает в себя подзадачи:

- создание набора данных (сбор снимков КТ брюшной полости на уровне позвонка L3, разметка мышечной ткани);
- разработка алгоритмов предварительной обработки снимков КТ;
- построение, обучение и тестирование моделей сегментации;
- разработка алгоритмов постобработки масок сегментации;
- разработка алгоритмов, отвечающих за работу с файлами (загрузка данных из входных файлов, передача их алгоритмам обработки и сегментации, запись результатов в выходные файлы).

Описание набора данных

Набор данных, примененный для обучения нейронных сетей и тестирования подходов к обработке снимков, основанных на классическом компьютерном зрении, собран из данных КТ онкологических больных. Пациенты получили комбинированное лечение в Медицинском радиологическом научном центре им. А.Ф. Цыба и для них были доступны изображения КТ, полученные до операции. Для формирования набора рентгенологами были отобраны снимки КТ, соответствующие уровню позвонка L3.

Исследования выполнялись на мультиспиральном компьютерном томографе Optima CT660 (GE). Параметры КТ-исследования: напряжение 120 кВ; сила тока в среднем 95 мА·с (в зависимости от конституции пациента); матрица изображения 512 × 512 пикселей; толщина томографического среза — 5 мм, коллимация — 6 × 2 мм. Полученные КТ-данные реконструированы с толщиной среза 2,5 мм и инкрементом 1–1,5 мм.

КТ-исследования проведены в положении больного лежа на спине с вытянутыми над головой руками, при необходимости применялось полипозиционное исследование с целью улучшения визуализации. Топограмма

выполнена при задержке дыхания в фазу вдоха в кранио-окудальном направлении. По топограмме произведено планирование области исследования. Сделано нативное (бесконтрастное) исследование, затем сканирование с контрастным усилением по стандартной методике.

Разметка мышечной ткани, заключающаяся в формировании бинарных масок для всех снимков набора, произведена опытным рентгенологом, имеющим более 10 лет медицинского стажа. Набор данных содержит 207 снимков КТ на уровне позвонка L3 119 уникальных пациентов (67 мужчин, 52 женщины). Медианные возраста — 63 и 59,5 лет для снимков пациентов мужского и женского полов. Самому молодому пациенту 28 лет, самому возрастному — 81. Половозрастное распределение снимков показано на рис. 1. Набор разделен на обучающую, валидационную и тестовую выборки, содержащие 161, 23 и 23 снимков.

Описание разработанного модуля сегментации снимков

В основе логики функционирования разработанного модуля лежат три этапа.

Этап 1. Получение из файлов DICOM входных данных для нейронных сетей. Вне зависимости от того, какой метод обработки применялся к снимкам КТ, для всех DICOM-файлов выполнялись следующие шаги.

Шаг 1. Чтение массивов пикселей (ширина и высота каждого составляют 512 пикселей);

Шаг 2. Переход от значений пикселей к HU.

Для дальнейшей обработки снимков реализованы три подхода, с использованием которых осуществлено формирование различных вариантов входных данных для моделей сегментации. Первый подход основан на анализе изображения в HU (уровень и ширина окна принимаются равными рекомендованным,читывающим из DICOM, для большинства исследований 40 HU и 400 HU соответственно) при помощи применения порога и выделения контура тела (через анализ размеров и положений). Данный подход необходим для маскирования всего, что лежит за пределами тела пациента: пиксели, относящиеся к областям стола томографа и рук пациента, преобразуются в черные.

Второй подход базируется на одном из методов классической обработки снимков — адаптивном выравнивании гистограмм с ограниченным усилением контраста (Contrast Limited Adaptive Histogram Equalization,

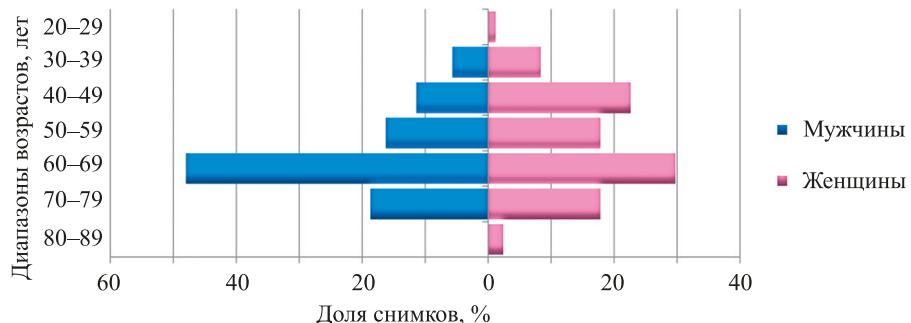


Рис. 1. Половозрастное распределение снимков

Fig. 1. Age and gender distribution of images

CLAHE). Цель применения подхода заключается в повышении контрастности изображения, в рамках исследования применяются пределы отсечения (Clip Limit, CL), равные 1, 2 и 3.

Для снимков КТ характерно нежелательное изменение значений пикселей — шум. Он приводит к снижению качества изображения и ухудшает контрастное разрешение. Увеличение отношения сигнал/шум (Signal/Noise Rate, SNR) представляет собой важную задачу. При уменьшении уровня шума должны сохраняться детали исходного изображения, чтобы оно не теряло клинически значимого содержания. Метод шумоподавления на базе применения анизотропного диффузационного фильтра (Anisotropic Diffusion Filter, ADF) лишен недостатков, связанных с размытием краев (для пространственных фильтров), сложностью правильного выбора частотных характеристик (для временных фильтров), порогов и масштабов (для вейвлетов), возникновением артефактов, отбрасыванием деталей мелких структур [18]. Исходя из этого, третий подход служит для предварительной обработки, отвечает за уменьшение уровня шума и основан на ADF.

Для обучения моделей сегментации применены 9 вариантов формирования входных данных:

- одноканальные базовые снимки с переходом к HU (*base*);
- одноканальные снимки *base*, на которых замаскировано все, кроме тела пациента (*masked*);
- одноканальные снимки *masked* с применением CLAHE с CL, равными 1, 2 и 3 (*CLAHE 1*, *CLAHE 2* и *CLAHE 3*);
- одноканальные снимки *masked* с примененным ADF (*ADF*);
- одноканальные снимки *masked* с последовательно примененными CLAHE с CL, равным 2, и ADF (*CLAHE ADF*);
- трехканальные снимки, у которых первый канал представляет *masked*, второй — *CLAHE 2*, третий — *ADF* (*3 channels*);
- двухканальные снимки, у которых первый канал представляет *masked*, второй — *CLAHE 2* (*2 channels*).

На рис. 2 показаны разные варианты одного снимка КТ.

Этап 2. Сегментация снимков и формирование для них бинарных масок, в которых белые пиксели соответствуют мышечной ткани, а черные — областям, ле-

жащим за ее пределами. Для этого построены, обучены и протестированы 63 нейросетевых модели, имеющие 7 различных архитектур (для каждого из 9 вариантов входных данных — отдельная сеть). Все реализованные архитектуры объединяют то, что в основе лежат две подсети (кодер и декодер), однако каждая из них имеет свои особенности:

- U-Net представляет собой базовую архитектуру, самую легковесную из рассмотренных;
- Attention U-Net имеет ворота внимания, которые позволяют сети подавлять ненужные области и сосредотачивать внимание на существенных деталях различных форм и размеров;
- U-Net++ основана на вложенных плотных пропускных соединениях, введение которых призвано устраниить семантический разрыв между картами признаков кодера и декодера;
- ResU-Net основана на использовании остаточных соединений, изучающих остаточные признаки со ссылкой на входные данные;
- Inception U-Net имеет блоки, которые позволяют использовать несколько типов размера фильтра вместо того, чтобы ограничиваться одним размером;
- Dense U-Net основана на замене базовых блоков U-Net на плотные блоки, позволяющей создавать более глубокие модели для более точной сегментации;
- U²-Net представляет собой двухуровневуюложенную архитектуру, способную захватывать больше контекстной информации из разных масштабов и увеличивающую глубину анализа.

Этап 3. Постобработка бинарных масок сегментации, предсываемых моделями, для устранения «артефактов» сегментации — белых пикселей, лежащих вне области интереса. Этот этап важен, так как позволяет предотвратить не только некорректную оценку площади мышечной ткани, но и ошибки в определении ее показателей в HU (минимум, максимум, среднее, стандартное отклонение). Предложенный алгоритм постобработки базируется на анализе контуров:

- белые пиксели, лежащие внутри эллипса, вписанного в область интереса (ограничена внутренней стороной мышечной ткани), преобразуются в черные;
- белые пиксели, лежащие за пределами эллипса, описанного вокруг области интереса (ограничивает внешнюю сторону мышечной ткани), преобразуются в черные.

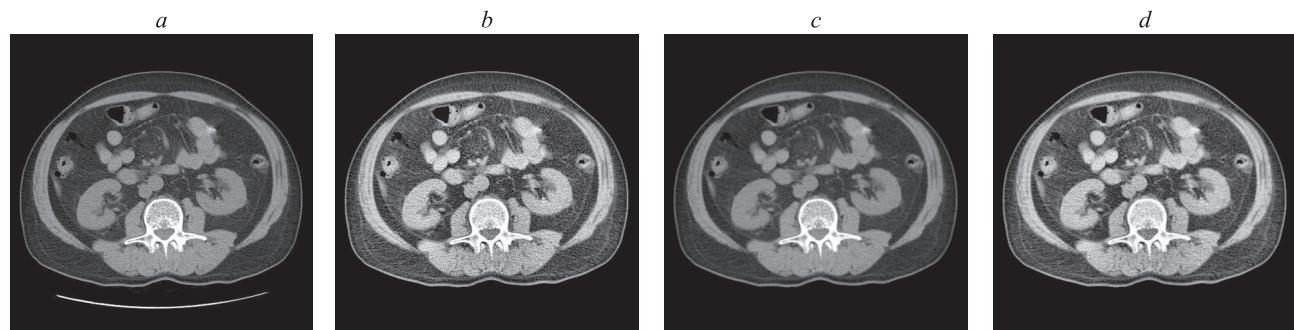


Рис. 2. Варианты входных снимков: *base* (a); *CLAHE 2* (b); *ADF* (c); *CLAHE ADF* (d)

Fig. 2. Variations of input images: *base* (a); *CLAHE 2* (b); *ADF* (c); *CLAHE ADF* (d)

Полученные результаты

Программный код разработанного модуля реализован на языке Python. Для создания, обучения и тестирования моделей сегментации использован фреймворк Keras, созданный на базе платформы TensorFlow.

Модуль получает на вход файл DICOM, формирует входные данные для модели, преобразуя содержащийся в нем снимок к необходимому виду, сегментирует снимок, обрабатывает полученную маску сегментации. На рис. 3 показан пример предварительно обработанного снимка и соответствующих ему масок сегментации мышечной ткани: истинной (сформирована рентгенологом) и предсказанной (результат работы модуля).

Для оценки моделей сегментации применены две метрики: DSC и пересечение над объединением (Intersection over Union, IoU). Для их расчета использованы следующие формулы:

$$DSC = 2 \cdot \frac{|pred \cap ground_truth|}{|pred| + |ground_truth|}$$

$$IoU = \frac{|pred \cap ground_truth|}{|pred \cup ground_truth|}.$$

где *pred* — маска, предсказанная моделью; *ground truth* — маска, полученная при разметке снимка рентгенологом. Значения DSC и IoU (табл. 1) рассчитаны для масок тестовых выборок, соответствующих

всем описанным типам входных данных. Ко всем маскам, предсказанным моделями, применен алгоритм постобработки, что позволило повысить значения DSC и IoU в среднем на 0,18 % и 0,32 %. Для 5 архитектур из 7 рассмотренных входных данных с применением методов обработки дают лучшие DSC, чем базовые снимки с переходом к HU. В 6 случаях из 7 обработанных данных получены наилучшие значения IoU. Самая легкая из рассмотренных архитектур, U-Net, имеющая 1 940 817 обучаемых параметров с применением данных 3 channel, достигла значения DSC, которое всего на 0,0015 меньше, чем максимальное из достигнутых (для Inception U-Net, имеющей 18 082 757 обучаемых параметров). При этом U-Net требует значительно меньше вычислительных и временных ресурсов для обучения, а также обеспечивает возможность использования модуля на менее мощных вычислительных устройствах. Это говорит о преимуществах применения предложенного подхода к формированию входных данных для моделей сегментации.

Время обработки модулем одного снимка в зависимости от выбранной модели сегментации (табл. 2) измерено для двух конфигураций вычислительного устройства: с графическим процессором NVIDIA GeForce RTX 3080 и без него, т. е. только с центральным процессором. Среднее время обработки снимка для конфигурации с центральным процессором не превышает 2 с, что значительно меньше времени, затрачиваемого рентгенологом при ручной разметке.

Таблица 1. Значения DSC и IoU
Table 1. DSC and IoU values

Типы входных данных	Архитектуры моделей сегментации						
	U-Net	Attention U-Net	U-Net++	ResU-Net	Inception U-Net	Dense U-Net	U ² -Net
Значения DSC							
base	0,9320	0,9235	0,9333	0,9366	0,9346	0,9374	0,9358
masked	0,9302	0,9288	0,9321	0,9290	0,9353	0,9341	0,9350
CLAHE 1	0,9322	0,9062	0,9317	0,9322	0,9355	0,9325	0,9370
CLAHE 2	0,9304	0,9296	0,9287	0,9303	0,9329	0,9349	0,9343
CLAHE 3	0,9315	0,9202	0,9287	0,9296	0,9339	0,9333	0,9351
ADF	0,9328	0,9277	0,9338	0,9341	0,9379	0,9360	0,9347
CLAHE ADF	0,9295	0,9297	0,9290	0,9241	0,9323	0,9357	0,9353
3 channels	0,9364	0,9180	0,9330	0,9363	0,9333	0,9370	0,9350
2 channels	0,9310	0,9285	0,9356	0,9342	0,9351	0,9349	0,9366
Значения IoU							
base	0,8735	0,8583	0,8765	0,8811	0,8770	0,8821	0,8796
masked	0,8700	0,8679	0,8737	0,8679	0,8783	0,8771	0,8781
CLAHE 1	0,8722	0,8330	0,8728	0,8742	0,8789	0,8727	0,8810
CLAHE 2	0,8691	0,8688	0,8688	0,8701	0,8745	0,8772	0,8755
CLAHE 3	0,8713	0,8525	0,8682	0,8679	0,8760	0,8749	0,8772
ADF	0,8736	0,8669	0,8771	0,8771	0,8824	0,8796	0,8767
CLAHE ADF	0,8673	0,8691	0,8678	0,8602	0,8748	0,8789	0,8787
3 channels	0,8802	0,8506	0,8760	0,8804	0,8759	0,8822	0,8779
2 channels	0,8706	0,8675	0,8794	0,8778	0,8779	0,8770	0,8802

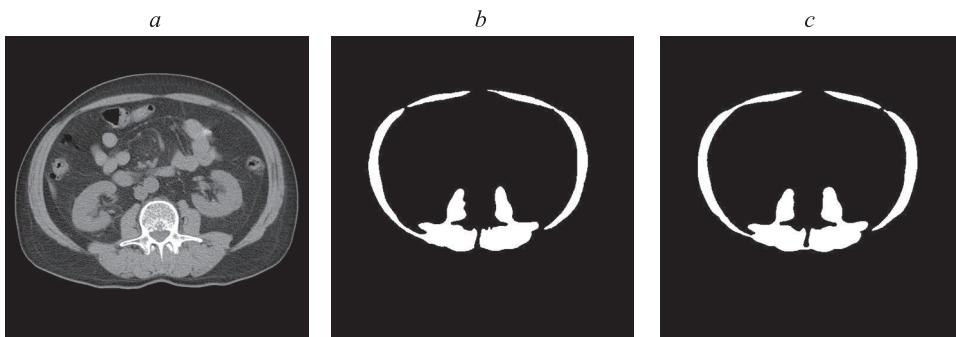


Рис. 3. Пример снимка и соответствующих ему масок сегментации: снимок модификации *masked* (*a*); истинная (*b*); предсказанная (*c*)

Fig. 3. Example of an image and corresponding segmentation masks: masked image (*a*); true mask (*b*); predicted mask (*c*)

Таблица 2. Среднее время обработки одного снимка, мс

Table 2. Average processing time per image, ms

Архитектуры моделей сегментации	Конфигурация вычислительного устройства	
	с графическим и центральным процессорами	с центральным процессором
U-Net	42,0	133
Attention U-Net	54,0	389
U-Net++	60,0	510
ResU-Net	52,2	358
Inception U-Net	90,8	1650
Dense U-Net	72,5	685
U ² -Net	102,0	925

Контуры, формируемые модулем сегментации, позволяют получать оценку площади мышц. Далее эта площадь должна быть нормализована к квадрату роста, чтобы быть представительной для оценки мышечной массы человека в целом. Исходя из этого, следующим шагом при КТ-саркометрии является вычисление скелетно-мышечного индекса, равного отношению полученного показателя площади скелетной мускулатуры на уровне тела L3 позвонка к квадрату показателя роста пациента. Расчет скелетно-мышечного индекса (SMI) выполняется по формуле:

$$SMI = \frac{S}{h^2}$$

где S — площадь всех групп мышц, попавших в срез, см^2 ; h — рост человека, м.

Далее полученные значения скелетно-мышечного индекса сравниваются с референсными. Большинство авторов считают пороговым значением SMI , ниже которого состояние мышечной ткани расценивается как саркопения: $52,4 \text{ см}^2/\text{м}^2$ для мужчин и $38,5 \text{ см}^2/\text{м}^2$ для женщин [19, 20].

Заключение

Разработан программный модуль, позволяющий в автоматическом режиме сегментировать мышечную

ткань по снимкам компьютерной томографии на уровне позвонка L3, тем самым упрощая процесс оценки мышечной массы при диагностике саркопении. Для обучения нейросетевых моделей собран и размечен набор данных, содержащий 207 снимков компьютерной томографии брюшной полости. Несмотря на небольшой объем обучающей выборки, достигнуты значения: коэффициента схожести Дайса равное 0,9374 и пересечение над объединением — 0,8822. Реализован ряд подходов к формированию входных данных моделей, позволяющих повысить точность сегментации. Один из подходов приближает точность легковесной U-Net к точностям более сложных архитектур, что является важным для применения в условиях ограниченных вычислительных ресурсов при применении в клинической практике. Результаты исследования подтверждают целесообразность применения компьютерного зрения для оценки показателей мышечной ткани, поэтому в рамках его развития планируется собрать и разметить больше обучающих данных, а также разработать модуль автоматического поиска снимка на уровне позвонка L3 по полной компьютерной томограмме пациента, модуль анализа гистограмм в единицах Хаунсфилда, программу для отображения медицинских данных с возможностью интеграции вышеупомянутых модулей.

16. Islam S., Kanavati F., Arain Z., Da Costa O.F., Crum W., Aboagye E.O., Rockall A.G. Fully automated deep-learning section-based muscle segmentation from CT images for sarcopenia assessment // *Clinical Radiology*. 2022. V. 77. N 5. P. e363–e371. <https://doi.org/10.1016/j.crad.2022.01.036>
17. Takahashi N., Sugimoto M., Psutka S.P., Chen B., Moynagh M.R., Carter R.E. Validation study of a new semi-automated software program for CT body composition analysis // *Abdominal Radiology*. 2017. V. 42. N 9. P. 2369–2375. <https://doi.org/10.1007/s00261-017-1123-6>
18. Kaur R., Juneja M., Mandal A.K. A comprehensive review of denoising techniques for abdominal CT images // *Multimedia Tools and Applications*. 2018. V. 77. N 17. P. 22735–22770. <https://doi.org/10.1007/s11042-017-5500-5>
19. Масенко В.Л., Коков А.Н., Григорьева И.И., Кривошапова К.Е. Лучевые методы диагностики саркопении // Исследования и практика в медицине. 2019. Т. 6. № 4. С. 127–137. <https://doi.org/10.17709/2409-2231-2019-6-4-13>
20. Lee J.S., Kim Y.S., Kim E.Y., Jin W. Prognostic significance of CT-determined sarcopenia in patients with advanced gastric cancer // *PLoS ONE*. 2018. V. 13. N 8. P. e0202700. <https://doi.org/10.1371/journal.pone.0202700>
16. Islam S., Kanavati F., Arain Z., Da Costa O.F., Crum W., Aboagye E.O., Rockall A.G. Fully automated deep-learning section-based muscle segmentation from CT images for sarcopenia assessment. *Clinical Radiology*, 2022, vol. 77, no. 5, pp. e363–e371. <https://doi.org/10.1016/j.crad.2022.01.036>
17. Takahashi N., Sugimoto M., Psutka S.P., Chen B., Moynagh M.R., Carter R.E. Validation study of a new semi-automated software program for CT body composition analysis. *Abdominal Radiology*, 2017, vol. 42, no. 9, pp. 2369–2375. <https://doi.org/10.1007/s00261-017-1123-6>
18. Kaur R., Juneja M., Mandal A.K. A comprehensive review of denoising techniques for abdominal CT images. *Multimedia Tools and Applications*, 2018, vol. 77, no. 17, pp. 22735–22770. <https://doi.org/10.1007/s11042-017-5500-5>
19. Masenko V.L., Kokov A.N., Grigoreva I.I., Krivoshapova K.E. Radiology methods of the sarcopenia diagnosis. *Research and Practical Medicine Journal*, 2019, vol. 6, no. 4, pp. 127–137. (in Russian). <https://doi.org/10.17709/2409-2231-2019-6-4-13>
20. Lee J.S., Kim Y.S., Kim E.Y., Jin W. Prognostic significance of CT-determined sarcopenia in patients with advanced gastric cancer. *PLoS ONE*, 2018, vol. 13, no. 8, pp. e0202700. <https://doi.org/10.1371/journal.pone.0202700>

Авторы

Теплякова Анастасия Романовна — преподаватель, аспирант, Обнинский институт атомной энергетики — филиал федерального государственного автономного образовательного учреждения высшего образования «Национальный исследовательский ядерный университет «МИФИ» (ИАТЭ НИЯУ МИФИ), Обнинск, 249039, Российская Федерация, <https://orcid.org/0000-0001-8612-3850>, anastasiya-t23@mail.ru

Шершинев Роман Владимирович — старший преподаватель, Обнинский институт атомной энергетики — филиал федерального государственного автономного образовательного учреждения высшего образования «Национальный исследовательский ядерный университет «МИФИ» (ИАТЭ НИЯУ МИФИ), Обнинск, 249039, Российская Федерация, <https://orcid.org/0009-0000-2324-5893>, rvshershnev@yandex.ru

Старков Сергей Олегович — доктор физико-математических наук, профессор, старший научный сотрудник, Обнинский институт атомной энергетики — филиал федерального государственного автономного образовательного учреждения высшего образования «Национальный исследовательский ядерный университет «МИФИ» (ИАТЭ НИЯУ МИФИ), Обнинск, 249039, Российская Федерация, <https://orcid.org/0000-0002-0420-7856>, sergeystarkov56@mail.ru

Агабабян Татев Артаковна — кандидат медицинских наук, заведующая отделением, Медицинский радиологический научный центр им. А.Ф. Цыба — филиал ФГБУ «Национальный медицинский исследовательский центр радиологии» Минздрава России, Обнинск, 249036, Российская Федерация, <https://orcid.org/0000-0002-9971-3451>, tatevik.05@mail.ru

Кукарская Валерия Андреевна — клинический ординатор, Медицинский радиологический научный центр им. А.Ф. Цыба — филиал ФГБУ «Национальный медицинский исследовательский центр радиологии» Минздрава России, Обнинск, 249036, Российская Федерация, <https://orcid.org/0009-0001-4872-3182>, kukarely@mail.ru

Authors

Anastasia R. Teplyakova — PhD Student, Lecturer, Obninsk Institute for Nuclear Power Engineering, Obninsk, 249039, Russian Federation, <https://orcid.org/0000-0001-8612-3850>, anastasiya-t23@mail.ru

Roman V. Shershnev — Senior Lecturer, Obninsk Institute for Nuclear Power Engineering, Obninsk, 249039, Russian Federation, <https://orcid.org/0009-0000-2324-5893>, rvshershnev@yandex.ru

Sergey O. Starkov — D.Sc. (Physics & Mathematics), Professor, Senior Researcher, Obninsk Institute for Nuclear Power Engineering, Obninsk, 249039, Russian Federation, <https://orcid.org/0000-0002-0420-7856>, sergeystarkov56@mail.ru

Tatev A. Agababian — PhD (Medicine), Head of Department, A. Tsyb Medical Radiological Research Centre — branch of the National Medical Research Radiological Center of the Ministry of Health of the Russia, Obninsk, 249036, Russian Federation, <https://orcid.org/0000-0002-9971-3451>, tatevik.05@mail.ru

Valeria A. Kukarskaya — Clinical Resident, A. Tsyb Medical Radiological Research Centre — branch of the National Medical Research Radiological Center of the Ministry of Health of the Russia, Obninsk, 249036, Russian Federation, <https://orcid.org/0009-0001-4872-3182>, kukarely@mail.ru

Статья поступила в редакцию 21.11.2023
Одобрена после рецензирования 25.12.2023
Принята к печати 24.01.2024

Received 21.11.2023
Approved after reviewing 25.12.2023
Accepted 24.01.2024



Работа доступна по лицензии
Creative Commons
«Attribution-NonCommercial»