

Применение подходов радиомики в обработке данных компьютерной томографии при определении саркопении

Я. А. Шмидт, Е. Д. Котина

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

Для цитирования: Шмидт Я. А., Котина Е. Д. Применение подходов радиомики в обработке данных компьютерной томографии при определении саркопении // Вестник Санкт-Петербургского университета. Прикладная математика. Информатика. Процессы управления. 2024. Т. 20. Вып. 3. С. 376–390. <https://doi.org/10.21638/spbu10.2024.306>

В статье представлен алгоритм, реализующий радиомический подход к обработке данных компьютерной томографии (КТ) для диагностики саркопении. Предлагаемый метод включает выделение области интереса, автоматическую сегментацию мышц с использованием моделей глубокого обучения, извлечение из КТ-изображений радиомических признаков, построение корреляционных матриц и выбор критериев для классификации. Результаты показывают, что полученные радиомические параметры имеют значимую корреляцию с наличием саркопении. Это позволяет строить точные модели классификации на основе машинного обучения. Данный подход может значительно улучшить диагностику саркопении, предоставляя надежные неинвазивные методы анализа.

Ключевые слова: радиомика, текстовый анализ, машинное обучение, саркопения.

1. Введение. С развитием методов медицинской визуализации, таких как компьютерная томография (КТ), магнитнорезонансная томография (МРТ), однофотонная эмиссионная компьютерная томография (ОФЭКТ), позитронно-эмиссионная томография (ПЭТ), гибридные методы (ПЭТ/КТ, ОФЭКТ/КТ, ПЭТ/МРТ), постепенно увеличивался объем изучаемых данных и потенциально значимых параметров исследований, поэтому возникла необходимость в разработке специальных подходов к анализу диагностических изображений на основе методов текстового анализа и искусственного интеллекта. Радиомика — относительно новое направление в развитии точной медицины, которое предполагает количественный анализ медицинских изображений, включающий вычисление текстовых признаков изображений, характеризующих структурные особенности тканей, и дальнейший анализ на основе машинного обучения и искусственного интеллекта. Данный подход используется в предлагаемой статье для выявления саркопении.

Саркопения характеризуется прогрессирующей потерей мышечной массы и силы, которая есть серьезная проблема, затрагивающая миллионы людей по всему миру. Эта патология встречается в клинической практике среди различных категорий пациентов и является независимым фактором риска развития осложнений. В частности, значительно усложняется реабилитационный процесс после хирургического вмешательства, что особенно характерно для пациентов онкологического профиля. Профилактика и своевременное лечение могут снизить риск всевозможных неблагоприятных последствий. Как известно, КТ относится к стандартным методам при предоперационной диагностике, а также при стадировании разных групп онкологических заболеваний, и дополнительно полученные на основе КТ данные сведения

о наличии или отсутствии саркопении представляют собой важную диагностическую информацию.

Для определения саркопении существует ряд методов скрининга (SARC-F, замер антропометрических данных, анализ походки [1], генома [2] и метаданных пациентов [3]), а также методов диагностирования [4] (DEXA, БИА, мышечная биопсия, МРТ, ПЭТ), в том числе на основе КТ. Однако авторы многих статей указывают на отсутствие стандартизации в различных методах диагностики саркопении, прежде всего лучевой диагностики [5–7]. В настоящее время при оценке саркопении на основе КТ-изображений используются два основных показателя [8, 9] — SMI (скелетно-мышечный индекс) и PMI (скелетный индекс m.Psoas), однако для них нет конкретных количественных пороговых значений [7].

На основе машинного обучения можно предложить более эффективные и надежные методы диагностики саркопении, применяя радиомические параметры, извлеченные из медицинских изображений, таких как КТ формата DICOM, который представляет собой международный стандарт медицинских данных и расшифровывается как Digital Imaging and COmmunications in Medicine.

Обычно структуры, визуализируемые на КТ, представлены в градациях серого. Отметим, что DICOM-изображения имеют широкий диапазон цифровых значений, чисел Хаунсфилда (HU), и даже при использовании оконного просмотра все детали изображений не могут быть восприняты человеческим глазом, который в среднем различает только порядка 80 градаций серого, а единицы HU принадлежат примерно диапазону $[-1000, 3000]$, где воде соответствует 0 HU, а воздуху — значение -1000 HU. В работах [10, 11] обосновывается применение радиомических параметров в медицинских задачах, которое предоставляет способ извлекать низкоуровневые признаки, недоступные человеческому глазу и позволяющие построить на их основе точные модели бинарной классификации.

В настоящей работе предлагается использовать методы машинного обучения и радиомические параметры, извлеченные из КТ-изображений, взятых на уровне третьего поясничного позвонка (L3), для диагностики саркопении. Ожидается, что такой подход позволит повысить точность и эффективность диагностики саркопении. Это исследование продолжает работы авторов в данном направлении. Так, авторами были обучены модели сегментации мышц [12], получены первые результаты в поиске корреляции радиомических параметров с наличием саркопении [13, 14].

Поскольку КТ-данные представимы набором двумерных срезов, то необходимо из имеющегося трехмерного массива извлекать требуемый срез, который находится на уровне L3 позвоночника. В основном предлагается выбирать данный срез для оценки саркопении [9], поскольку можно сократить размерность входных данных и количество параметров итоговой модели, а также ускорить процесс обработки исследований.

Дальнейшее выделение области интереса производится автоматически с применением модели сегментации мышечных структур. Были обучены модели различных архитектур (LinkNet, DeepLabV3, DeepLabV3+) с разными кодировщиками (ResNet, MobileNet, EfficientNet), среди которых были отобраны доставляющие наивысшие показатели целевых метрик на тестовых данных.

В статье основное внимание будет уделяться поиску новых параметров, позволяющих проводить неинвазивное определение саркопении у пациентов. Так, помимо текстурных параметров GLCM (Gray Level Co-occurrence Matrix), NGTDM (Neighborhood Gray Tone Difference Matrix) и FOS (First Order Statistics), используемых нами ранее, будет показано, что параметры GLSZM (Gray Level Size Zone Matrix),

GLRLM (Gray Level Run Length Matrix), FPS (Fourier Power Spectrum) также имеют значимую величину корреляции с рассматриваемым заболеванием. Использование таких параметров позволяет строить более точные классификационные модели.

2. Алгоритм обработки исследования. В настоящее время остается проблемой применение КТ для оценки степени снижения мышечной массы с использованием существующих индексов вследствие необходимости ручной сегментации мышечной ткани на КТ-изображениях, что затруднительно при большом потоке пациентов [7]. Однако с развитием нейронных сетей и глубокого обучения появились научные публикации, посвященные разработке моделей сегментации скелетных мышц на КТ-исследованиях и соответствующего программного обеспечения [12, 15, 16]. Но, как отмечается в статье [7], основным прикладным недостатком работ на данный момент является отсутствие соответствующих пограничных значений или же специального индекса для оценки качества мышечной ткани.

В этой работе предлагается общий алгоритм обработки данных КТ брюшной полости на основе подходов радиомики с целью выявления наличия саркопении. Радиомический подход предполагает следующие этапы обработки: выделение области интереса моделью сегментации мышц, извлечение параметров радиомики, исследование корреляции между параметрами и целевой переменной, отражающей наличие саркопении, а также построение модели для классификации пациентов.

Предполагается, что определение набора радиомических параметров (биомаркеров), характеризующих «качество» мышц, с целью построения классификационных моделей будет более эффективным подходом в решении задачи оценки саркопении, чем традиционные методы, основывающиеся на SMI-показателях. Рассматриваемые исследования представляют собой 3D-массивы КТ-данных, поэтому задача выделения области интереса происходит в два этапа: сначала выбирается нужный срез на уровне L3 позвончика, затем на этом срезе производится автоматическое выделение области мышц (сегментация). Далее вычисляются текстурные показатели, а также принимаются во внимание различные метаданные пациентов (возраст, пол), извлекаемые из DICOM-файлов и т. д.

Для дальнейшего построения модели необходимо определиться с теми параметрами, которые значимы при моделировании и будут входить в модель классификации. В качестве моделей классификации рассматриваются модели бинарной классификации, сравниваемые между собой. В результате работы моделей можно получить вероятность наличия саркопении у пациента. На рис. 1 представлены этапы предлагаемого алгоритма.

3. Модели глубокого обучения.

3.1. Модели сегментации. Под сегментацией в компьютерном зрении подразумевают построение контуров области интереса (ROI, Region Of Interest) и отделение области, заключенной в полученном полигоне, от остальных областей.

В настоящей работе среди моделей сегментации рассматривались такие архитектуры как LinkNet, DeepLabV3, DeepLabV3+. В качестве кодировщиков (model backbones) были выбраны модели EfficientNet, MobileNetV2, ResNet, поскольку они хорошо зарекомендовали себя как модели извлечения признаков из изображения. Кроме того, модели семейств EfficientNet и MobileNet являются весьма **легковесными** и могут быть использованы не только на мощных вычислительных машинах, но и на портативных устройствах, например на телефоне, что делает применение этих моделей на практике особенно актуальным.

LinkNet является улучшенной версией UNet, а DeepLabV3 / V3+ зарекомендова-

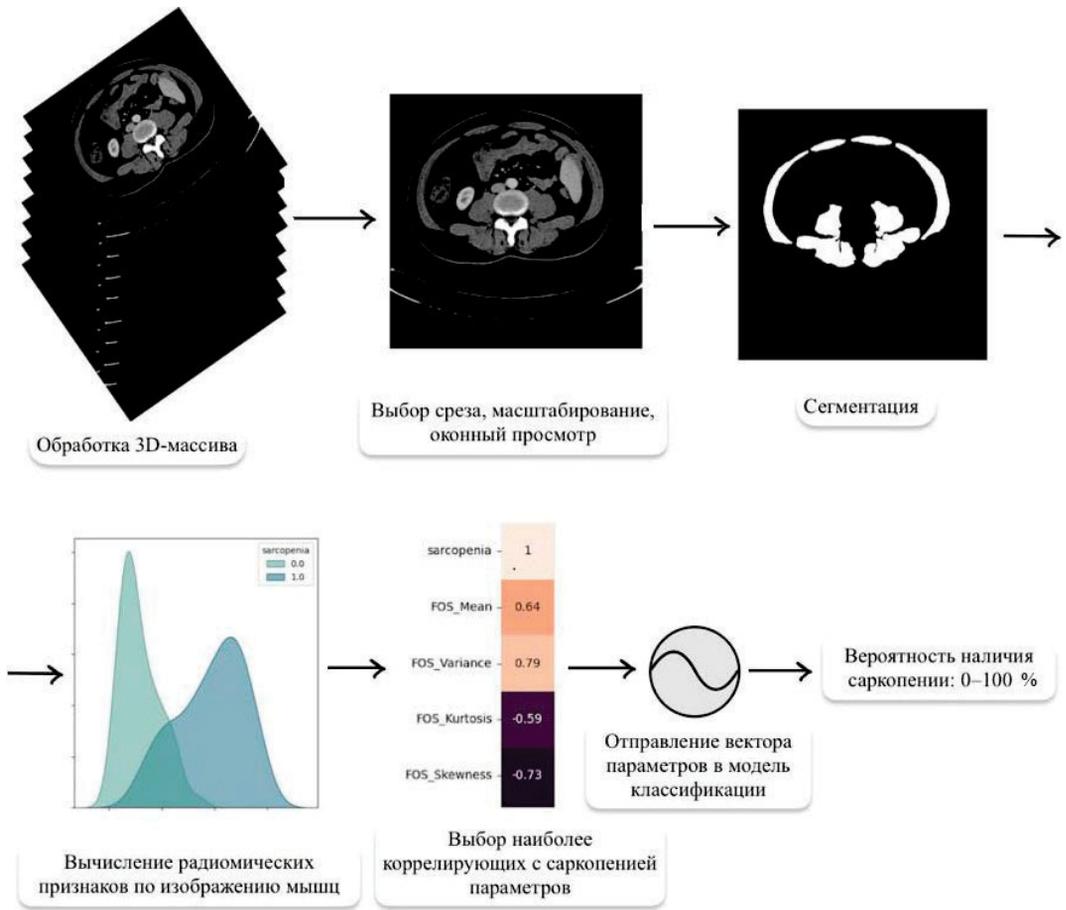


Рис. 1. Этапы алгоритма обработки

ли себя как одни из лучших архитектур для сегментации изображений, геометрические размеры которых велики. КТ-изображения имеют разрешение 512×512 , поэтому модели DeepLabV3 / V3+ показали себя лучше. Модели DeepLabV3 используют специальный вид сверток (atrous convolutions) и модуль ASPP (atrous spatial pyramid pooling), что позволяет извлекать более детальную информацию изображений свертками различных масштабов.

3.2. Обучение моделей. В Google Colaboratory были обучены рассмотренные выше модели. Основной метрикой качества служил коэффициент Дайса (Dice), а как функция потерь была выбрана комбинация DiceLoss и BCELoss:

$$\mathcal{L}(x, y) = 0.25 \cdot \text{DiceLoss}(x, y) + \text{BCEWithLogitsLoss}(x, y),$$

где $\text{DiceLoss} = 1 - \text{Dice}(x, y)$, а $\text{BCEWithLogitsLoss}(x, y)$ — более стабильная с точки зрения вычислений функция CrossEntropyLoss, или BCELoss в бинарном случае.

Обучающая выборка насчитывала 449 КТ-изображений, размеченных вручную с помощью модуля разметки DICOM-снимков. Данные были взяты как из открытого источника The Cancer Imaging Archive [TCIA], так и из статьи авторов [13]. Имел место дисбаланс классов: фона примерно в 11–12 раз больше, чем мышц: $10.8 \cdot 10^7$ пик-

селей фона и $9.1 \cdot 10^6$ пикселей мышц. Эту информацию необходимо было учитывать при обучении. Результаты приведены в табл. 1.

Таблица 1. Сравнение обученных моделей сегментации

Модель	Энкодер	Параметры	mDice (val)	mDice (infer)
LinkNet	MobileNetV2	4.3M	0.8846	0.9064
	EfficientNet-b0	4.1M	0.8983	0.913
	EfficientNet-b2	7.9M	0.8777	0.9024
	EfficientNet-b4	17.8M	0.8995	0.9178
	EfficientNet-b6	41.2M	0.907	0.9205
	ResNet-34	21.7M	0.8656	0.8952
DeepLabV3	MobileNetV2	12.6M	0.8792	0.9014
	EfficientNet-b2	11.2M	0.7924	0.8228
	EfficientNet-b4	21.7M	0.9035	0.913
DeepLabV3+	MobileNetV2	4.3M	0.865	0.885
	EfficientNet-b2	8.6M	0.8839	0.9128
	EfficientNet-b4	18.6M	0.9018	0.9157
	EfficientNet-b6	41.9M	0.9131	0.9294

Примечание. В колонке mDice (val) показан средний Dice на валидации при обучении, в колонке mDice (infer) — средний Dice на инференсе.

Лучше всего на этапе применения модели на тестовых данных показала себя модель DeepLabV3+ / EfficientNet-b6, демонстрируя качество практически 93 % по метрике Дайс. Процесс обучения данной модели показан на рис. 2. Пример предсказания тензоров масок продемонстрирован на рис. 3.

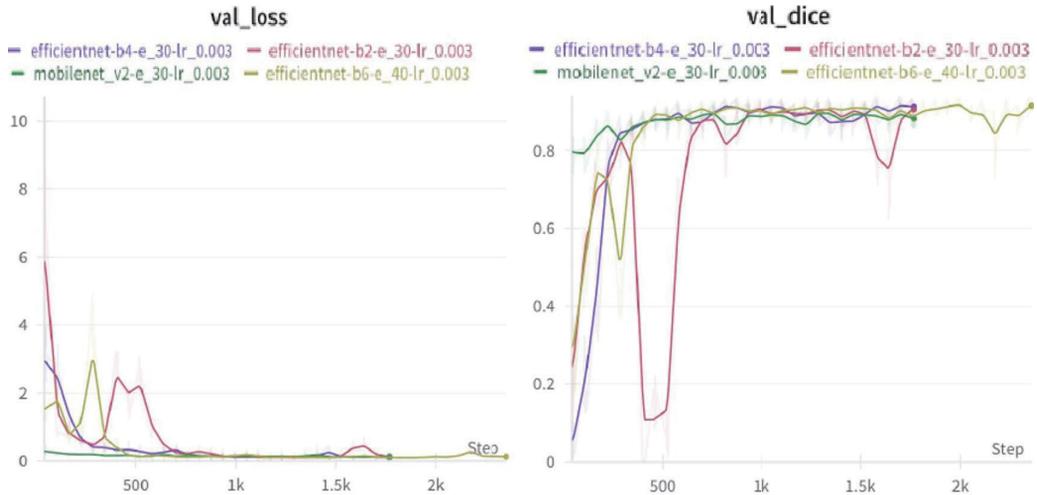


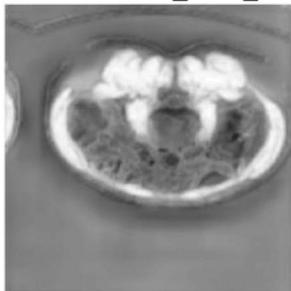
Рис. 2. График функции потерь и Дайса при валидации на этапе обучения

Получаемые маски проходят через порог активации (threshold), который был выбран равным 0.71, и в итоге получаются бинарные маски, где 1 соответствует предсказанным пикселям мышц, а 0 — фону (всему остальному, кроме мышц). Иллюстрация подбора порога активации приведена на рис. 4.

4. Определение параметров для моделирования.

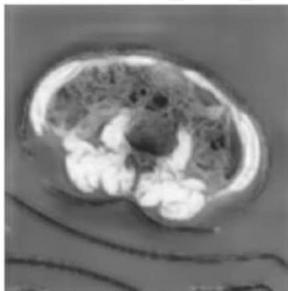
4.1. Извлечение радиомических параметров. В работе были рассмотрены следующие радиомические параметры: FOS, GLCM, NGTDM, выбор которых был

efficientnet-b4-e_30-lr_0.003



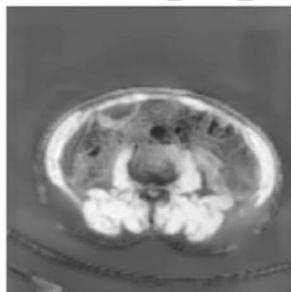
Valid pred, epoch № 29

efficientnet-b2-e_30-lr_0.003



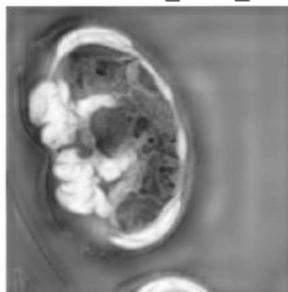
Valid pred, epoch № 29

mobilenet-v2-e_30-lr_0.003



Valid pred, epoch № 29

efficientnet-b6-e_40-lr_0.003



Valid pred, epoch № 39

Рис. 3. Предсказание масок моделями DeepLabV3+ с кодировщиками EfficientNet-b4 / b2, MobileNetV2, EfficientNet-b6 соответственно (слева направо)

обоснован в работах [13, 14], а также новые параметры, а именно: GLSZM, GLRLM, FPS — именно их было решено считать кандидатами на новые параметры, которые могли бы также коррелировать с наличием саркопении. Нахождение таких параметров позволит строить более точные модели классификации.

Рассмотрим способы определения данных радиомических параметров.

4.1.1. Параметры FOS. Статистики первого порядка рассчитываются по гистограммам распределения HU мышечных тканей, извлекаемых со снимка с помощью маски, которая вычисляется моделью сегментации по исходному КТ-снимку. Среди признаков первого порядка: выборочные среднее и дисперсия, эксцесс, коэффициент асимметрии, коэффициент вариации, 10-перцентиль и 25-перцентиль (1-й квартиль).

4.1.2. Параметры GLRLM. Пусть $N_s = \sum_{i=1}^N \sum_{j=1}^N r_{ij}$ — сумма всех интенсивностей пикселей снимка, N_v — число пикселей в области интереса (ROI).

1. Short run emphasis $\frac{1}{N_s} \sum_{j=1}^N \frac{r_{.j}}{j^2}$.
2. High grey level run emphasis $\frac{1}{N_s} \sum_{i=1}^N i^2 r_i$.
3. Short run high grey level emphasis $\frac{1}{N_s} \sum_{i=1}^N \sum_{j=1}^N \frac{i^2 r_{ij}}{j^2}$.
4. Run length non-uniformity $\frac{1}{N_s} \sum_{j=1}^N r_{.j}^2$.

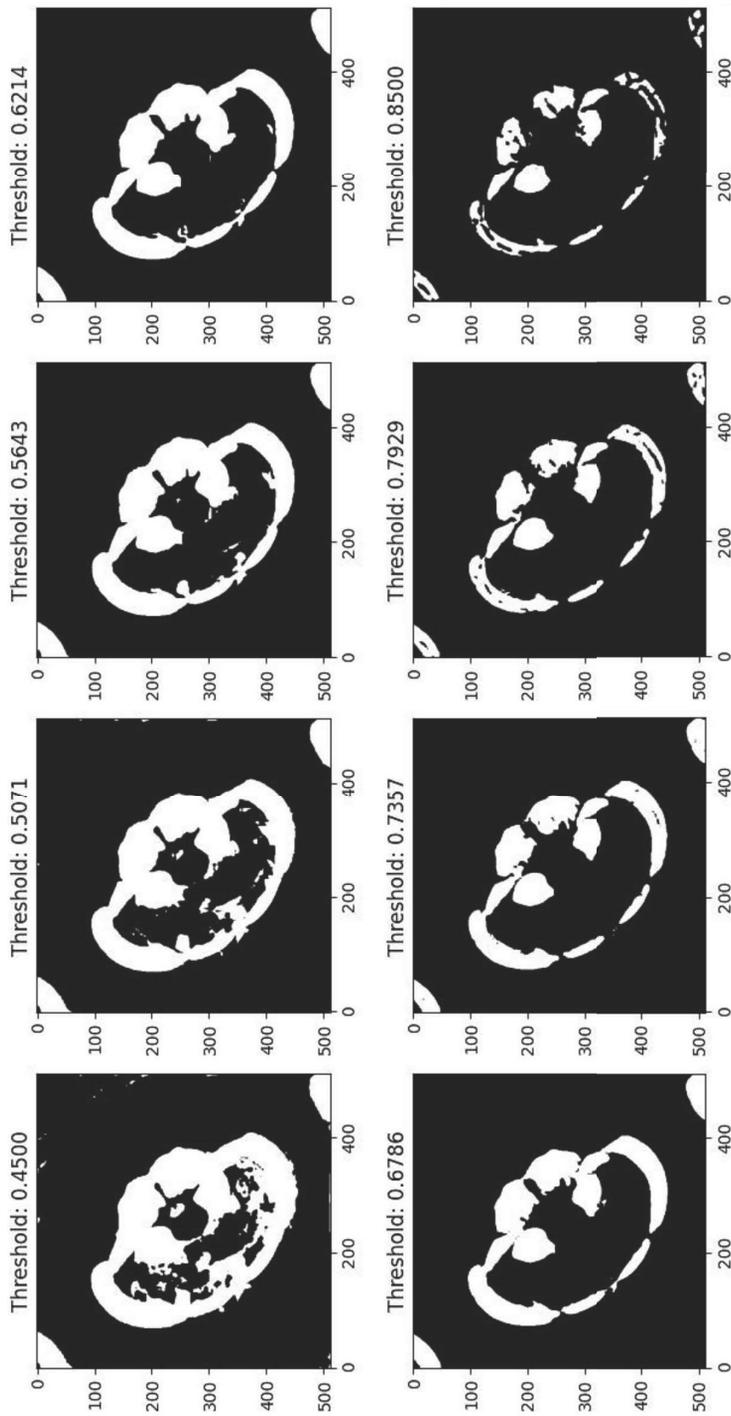


Рис. 4. Подбор порога активации для DeepLabV3+ / MobileNetV2

5. Run percentage $\frac{N_s}{N_v}$.

GLSZM основываются на GLRLM и подробно описаны в работе [17].

4.1.3. *Параметры GLCM.* $\mathbf{I}_{N \times N} \subset \mathbb{R}^2$ — двумерное изображение, GLCM — матрица $P(i, j)_{N \times N}$.

Элемент $a_{ij} \in [1, N] \in \mathbb{N}$ матрицы $P(i, j)$ получается подсчетом числа раз, когда пиксель со значением i является соседом пикселя интенсивности j :

$$P(i, j) = \sum_{m=1}^M \sum_{k=1}^K [(\mathbf{I}(m, k) = i) \& (\mathbf{I}(m + d_x, k + d_y) = j)],$$

где соседний пиксель определяется *вектором перемещения* $\delta = (d_x, d_y)$. Значения $d_x, d_y \in \mathbb{Z}$ указывают величину смещения по пикселям x, y [18]; $P(i, j)$ — матрица относительных частот совместной встречаемости,

$$p(i, j) = \frac{P(i, j)}{R} = \frac{P(i, j)}{\sum_{i=1}^N \sum_{j=1}^N P(i, j)}$$

— матрица вероятностей совместной встречаемости, в которой R — общее число вхождений: $R = \sum_{i=1}^N \sum_{j=1}^N P(i, j)$;

$$p_{x+y}(k) = \sum_{i=1}^N \sum_{j=1}^N \delta_{i+j, k} p(i, j) = \sum_{i=1}^N \sum_{j=1}^N [i + j = k] p(i, j), \quad k = \overline{2, \dots, 2N}.$$

1. Contrast $\sum_{i=1}^N \sum_{j=1}^N (i - j)^2 p(i, j)$.
2. Sum of Squares Variance $\sum_{i=1}^N \sum_{j=1}^N (i - \mu)^2 p_{ij}$.
3. Sum Variance $\sum_{k=2}^{2N} (k - \mu)^2 p_{i+j, \dots}$.
4. Sum Average $\sum_{k=2}^{2N} k p_{i+j, k}$.

4.1.4. *Параметры FPS.* Сначала вычисляется двумерное преобразование Фурье по ROI:

$$\mathbb{X} = X_{k_1, k_2, \dots, k_d} = \sum_{n_1=0}^{N_1-1} \left(\omega_{N_1}^{k_1 n_1} \sum_{n_2=0}^{N_2-1} \left(\omega_{N_2}^{k_2 n_2} \dots \sum_{n_d=0}^{N_d-1} \omega_{N_d}^{k_d n_d} \cdot x_{n_1, n_2, \dots, n_d} \right) \right),$$

здесь x_{n_1, n_2, \dots, n_d} — многомерный вектор d дискретных переменных $n_\ell = 0, 1, \dots, N_\ell - 1, \ell = 1, \dots, d$. В рассматриваемом случае $d = 2$.

Далее берутся вещественная и мнимая части от результата преобразования Фурье:

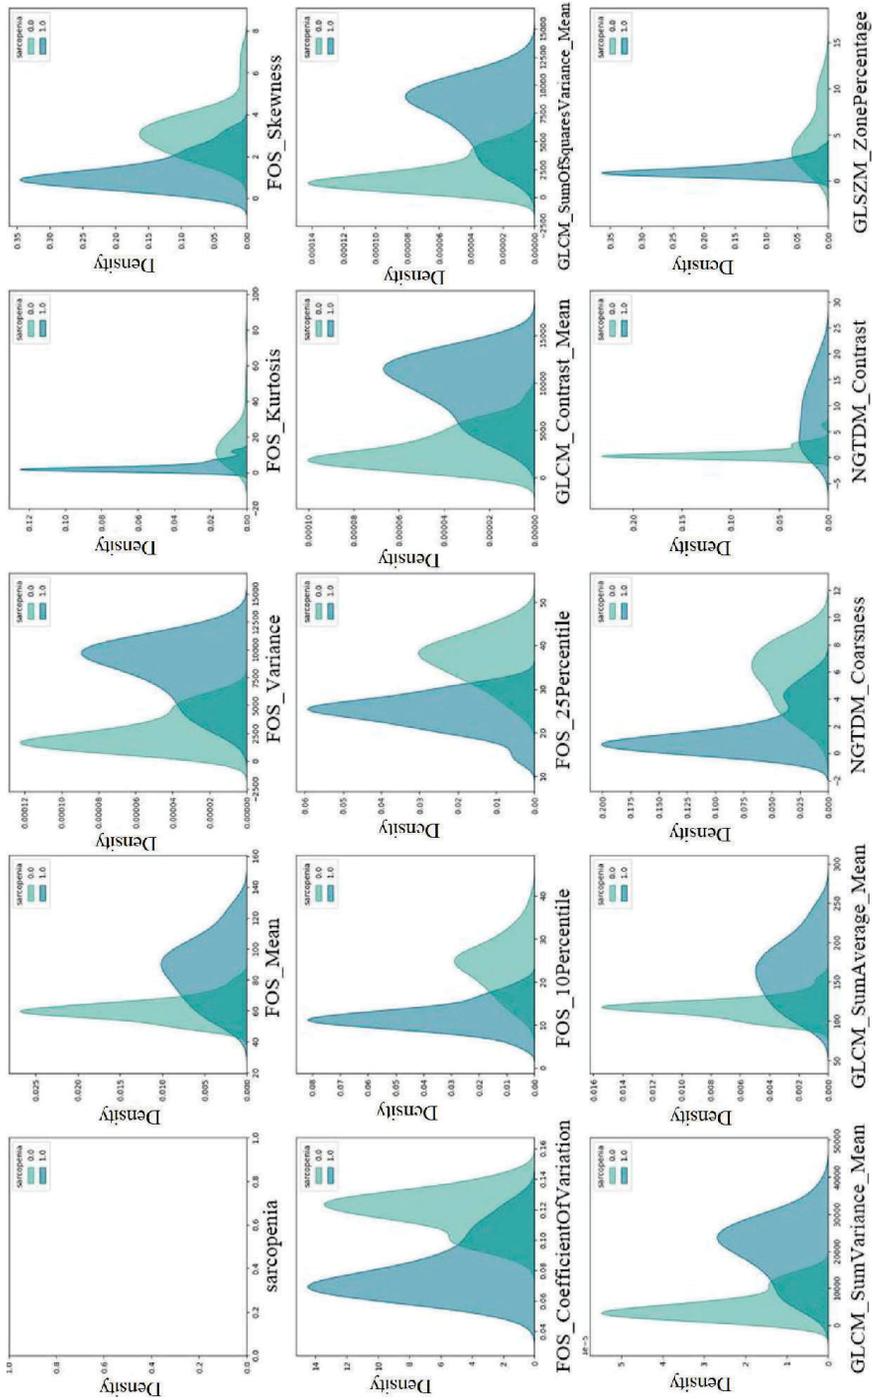
$$F_{\text{real}} = \Re(\mathbb{X}), \quad F_{\text{imag}} = \Im(\mathbb{X}).$$

По ним строятся параметры FPS.

1. Radial Sum $\sqrt{\frac{\sum \sum (F_{\text{real}} \cdot F_{\text{real}})}{\text{area}}}$.

2. Angular Sum $\sqrt{\frac{\sum \sum (F_{\text{imag}} \cdot F_{\text{imag}})}{\text{area}}}$, где area — площадь ROI, т. е. площадь мышц.

4.1.5. *Параметры NGTDM.* Пусть $X_{d, k} = X_d(\mathbf{k})$ — дискретизированный уровень серого пикселя, расположенного в $\mathbf{k} = (k_x, k_y)$. Тогда средний уровень серого в окрестности с центром (k_x, k_y) за исключением (k_x, k_y) определяется следующим образом:



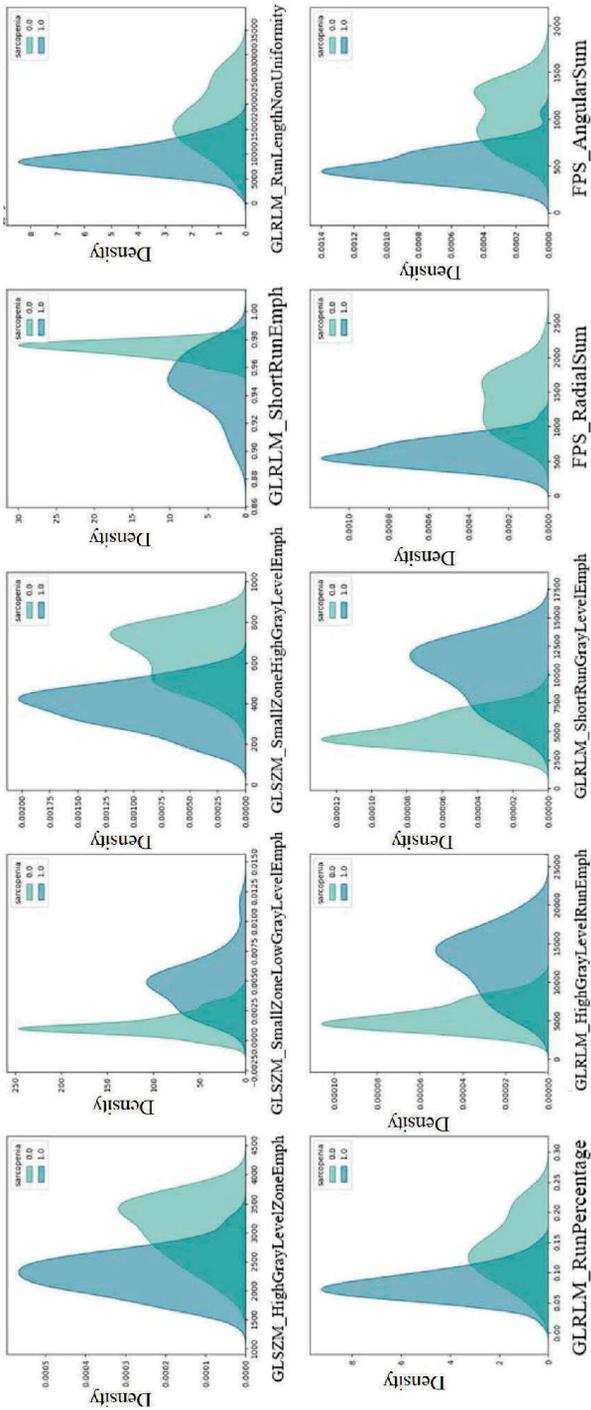


Рис. 5. Оценки плотностей распределения радиометрических параметров

$$\overline{X}_k = \frac{1}{W} \sum_{m_y=-\delta}^{\delta} \sum_{m_x=-\delta}^{\delta} X_d(k_x + m_x, k_y + m_y), \quad (m_x, m_y) \neq (0, 0), \quad W = (2\delta + 1)^2 - 1.$$

Запишем разность серых тонов окрестности s_i для дискретизированного уровня серого i в виде $s_i = \sum_k^{N_v} |i - \overline{X}_k| [(X_d(\mathbf{k}) = i) \& (k \text{ имеет допустимую окрестность})]$.

Contrast зависит от динамического диапазона уровней серого, а также от пространственной частоты изменения интенсивности

$$F_{\text{Contr}} = \left(\frac{1}{N_{g,p}(N_{g,p} - 1)} \sum_{i=1}^N \sum_{j=1}^N p_i p_j (i - j)^2 \right) \left(\frac{1}{N_{v,c}} \sum_{i=1}^N s_i \right),$$

здесь N_g — количество дискретизированных уровней серого в ROI, n_i — число вокселей с уровнем серого i , у которых ненулевое множество соседей, $N_{v,c} = \sum n_i$ — общее число вокселей, у которых есть хотя бы один сосед. Если у всех вокселей есть хотя бы один сосед, то $N_{v,c} = N_v$. Также $N_{g,p}$ — число дискретизированных уровней серого с $p_i > 0$, где $p_i = \frac{n_i}{N_{v,c}}$ — вероятность i -го уровня серого.

На языке Python были реализованы все программные решения, в том числе модуль для применения параллельных вычислений к библиотеке ruFeats, которая предоставляет методы для извлечения радиомических параметров из изображений.

Вычисление приведенных параметров для 113 пациентов с записью результатов в pandas dataframe или csv-файл занимает 235 с для всех перечисленных выше семейств параметров, что позволяет использовать данный модуль на практике.

Для параметров были построены матрицы корреляций Пирсона, Спирмена и Кенделла с тем, чтобы выяснить, какие из параметров имеют сильную корреляцию с наличием саркопении. Было выявлено, что среди параметров наиболее информативными при дальнейшем моделировании классификационных моделей являются параметры, приведенные в табл. 2. Именно они были выбраны в качестве основных для обучения моделей классификации. Как показано на рис. 5, рассматриваемые параметры варьируются в различных диапазонах, присущих конкретному классу.

Распределения параметров по классам «Пациенты с саркопенией», «Пациенты без саркопении» можно разделить, следовательно, в пространстве размерности 24, которое совпадает с количеством вычисляемых признаков, можно построить разделяющую гиперплоскость.

4.2. Классификация. Отобранные параметры, коррелирующие с наличием заболевания, предлагается использовать как признаки для обучения моделей бинарной классификации. Так, на этапе применения модели классификации саркопении для каждого пациента формируется вектор размерности 24, состоящий из извлекаемых по КТ-изображению радиомических параметров, которые применяются как вход для модели. В качестве ответа модель предоставляет вероятность наличия заболевания.

При обучении основными метриками классификации были Accuracy, Precision, Recall, F1. Модели обучались как на необработанных числовых данных, так и с помощью таких методов нормализации, как Standart, Robust и MinMax Scalars.

Логистическая регрессия — алгоритм классического машинного обучения. Модели случайного леса, градиентного бустинга, XGBoost и Extremely Randomized Trees — это методы ансамблирования. Они используют различные подходы к обучению, стремясь увеличить обобщающую способность алгоритма. Это достигается за счет усред-

Таблица 2. Радиомические параметры

Категория	Параметр	Корреляция
FOS	Mean	0.65
	Variance	0.78
	Kurtosis	-0.77
	Skewness	-0.76
	Coefficient of Variation	-0.76
	10 th Percentile	-0.81
	25 th Percentile	-0.8
GLCM	Contrast (Mean)	0.78
	Sum of Squares Variance (Mean)	0.78
	Sum Variance (Mean)	0.77
	Sum Average (Mean)	0.61
NGTDM	Coarseness	-0.73
	Contrast	0.72
GLSZM	Zone Percentage	-0.69
	High Gray Level Zone Emphasis	-0.66
	Small Zone Low Gray Level Emphasis	0.77
	Small Zone High Gray Level Emphasis	-0.75
GLRLM	Short Run Emphasis	-0.64
	Run Length Non-Uniformity	-0.66
	Run Percentage	-0.62
	High Gray Level Run Emphasis	0.76
	Short Run High Gray Level Emphasis	0.77
FPS	Radial Sum	-0.8
	Angular Sum	-0.76

нения решений нескольких базовых моделей, что помогает сократить вариативность и уменьшить вероятность переобучения. Кроме того, добавление нового слагаемого в ансамбль обычно осуществляется с учетом ошибок предыдущих обученных решающих правил, что способствует повышению обобщающей способности модели. Среди обученных моделей лучшее качество на этапе применения на тестовых данных показали модели XGBoost и Gradient Boosting, которые одинаково хорошо определяют наличие саркопии по 24 параметрам, извлекаемым из изображений (табл. 3).

Таблица 3. Результаты оценки моделей с разными нормализаторами

Модель	Accuracy	Precision	Recall	F1-score
LogisticRegression_L1	0.9	0.9	0.9	0.9
RandomForestClassifier	0.925	0.9474	0.9	0.9231
HistGradientBoostingClassifier	0.95	0.95	0.95	0.95
ExtraTreesClassifier	0.925	0.9474	0.9	0.9231
XGBClassifier	0.975	0.9524	1.0	0.9756
GradientBoostingClassifier	0.975	0.9524	1.0	0.9756

Малый вес, скорость применения и высокие значения метрик позволяют использовать данную модель для выявления наличия саркопии у пациентов по радиомическим параметрам, которые извлекаются из КТ-изображений на уровне L3 позвоночника.

5. Заключение. Были рассмотрены современные подходы к выявлению саркопии с помощью методов радиомики и алгоритмов машинного обучения. Были проведены обучение и тестирование различных моделей классификации на основе 24 радиомических параметров, извлекаемых из КТ-изображений на уровне L3. Модели классификации включали логистическую регрессию, случайный лес, градиентный бустинг, XGBoost и Extremely Randomized Trees. Результаты экспериментов показали, что модели XGBoost и Gradient Boosting демонстрируют наивысшую точность

и надежность, что делает их наиболее предпочтительными для использования в клинической практике при диагностике саркопении. Высокие показатели точности этих моделей и их удобство в применении дают возможность рассматривать их для практического использования.

Радиомические признаки, извлекаемые из КТ-изображений, способствуют более эффективному подходу к оценке саркопении по сравнению с традиционными методами, основанными на показателях SMI, PMI. Это открывает новые возможности для улучшения диагностики и мониторинга состояния пациентов. Таким образом, предложенный подход на основе радиомики и машинного обучения позволяет более точно и надежно определять наличие саркопении у пациентов, что может значительно улучшить результаты лечения и реабилитации.

Литература

1. *Chen Y.-C., Hsieh J.-W., Yang Y.-H., Lee C.-H., Yu P.-Y., Chen P.-Y., San A. S.* Towards deep learning-based sarcopenia screening with body joint composition analysis // 2021 IEEE International Conference on Image Processing (ICIP). Anchorage, AK, USA, 2021. P. 3807–3811. <https://doi.org/10.1109/ICIP42928.2021.9506482>
2. *Chung H., Jo Y., Ryu D., Jeong C., Choe S. K., Lee J.* Artificial-intelligence-driven discovery of prognostic biomarker for sarcopenia // Journal of Cachexia, Sarcopenia and Muscle. 2021. Vol. 12. N 6. P. 2220–2230. <https://doi.org/10.1002/jcsm.12840>
3. *Castillo-Olea C., Garcia-Zapirain S. B., Carballo L. C., Zuniga C.* Automatic classification of sarcopenia level in older adults: A case study at Tijuana General Hospital // International Journal of Environmental Research and Public Health. 2019. Vol. 16. N 18. P. 3275. <https://doi.org/10.3390/ijerph16183275>
4. *Ackermans L. L. G. C., Rabou J., Basrai M., Schweinlin A., Bischoff S. C., Cussenot O., Cancel-Tassin G., Renken R. J., Gomez E., Sanchez-Gonzalez P., Rainoldi A., Boccia G., Reisinger K. W., Bosch J. A. T., Blokhuis T. J.* Screening, diagnosis and monitoring of sarcopenia: When to use which tool? // Clin. Nutr. ESPEN. 2022. Vol. 48. P. 36–44. <https://doi.org/10.1016/j.clnesp.2022.01.027>
5. *Xie H., Gong Y., Kuang J., Yan L., Ruan G., Tang S., Gao F., Gan J.* Computed tomography-determined sarcopenia is a useful imaging biomarker for predicting postoperative outcomes in elderly colorectal cancer patients // Cancer Research and Treatment. 2020. Vol. 52. N 3. P. 957–972. <https://doi.org/10.4143/crt.2019.695>
6. *Jalal M., Campbell J. A., Wadsley J., Hopper A. D.* Computed tomographic sarcopenia in pancreatic cancer: Further utilization to plan patient management // Journal of Gastrointest Cancer. 2021. Vol. 52. N 3. P. 1183–1187. <https://doi.org/10.1007/s12029-021-00672-4>
7. *Сморчкова А. К., Петрайкин А. В., Семенов Д. С., Шарова Д. Е.* Саркопения: современные подходы к решению диагностических задач // Digital Diagnostics. 2022. Т. 3. № 3. С. 196–211. <https://doi.org/10.17816/DD110721>
8. *Ueki H., Hara T., Okamura Y., Bando Y., Terakawa T., Furukawa J., Harada K., Nakano Y., Fujisawa M.* Association between sarcopenia based on psoas muscle index and the response to nivolumab in metastatic renal cell carcinoma: A retrospective study // Investig. Clin. Urol. 2022. Vol. 63. N 4. P. 415–424. <https://doi.org/10.4111/icu.20220028>
9. *Kim S., Kim T.-H., Jeong C.-W., Lee C., Noh S., Kim J. E., Yoon K.-H.* Development of quantification software for evaluating body composition contents and its clinical application in sarcopenic obesity // Scientific Reports. 2020. Vol. 10. Art. N 10452. <https://doi.org/10.1038/s41598-020-67461-0>
10. *Chicklore S., Goh V., Siddique M., Roy A., Marsden P. K., Cook G. J. R.* Quantifying tumour heterogeneity in 18F-FDG PET/CT imaging by texture analysis // European Journal of Nuclear Medicine and Molecular Imaging. 2012. Vol. 40. N 1. P. 133–140. <https://doi.org/10.1007/s00259-012-2247-0>
11. *Cook G., Siddique M., Taylor B., Yip C., Chicklore S., Goh V.* Radiomics in PET: principles and applications // Clinical and Translational Imaging. 2014. Vol. 2. N 3. P. 269–276. <https://doi.org/10.1007/s40336-014-0064-0>
12. *Schmidt I., Kotina E., Buev P.* Deep learning muscle segmentation model for CT images in DICOM format // Cybernetics and Physics. 2023. Vol. 12. N 3. P. 201–206. <https://doi.org/10.35470/2226-4116-2023-12-3-201-206>
13. *Шмидт Я. А., Котина Е. Д., Камышанская И. Г., Макаренко Б. Г.* Радиомика в исследовании саркопении по КТ-изображениям // Диагностическая и интервенционная радиология. 2024. Т. 18. № S2.1. С. 94–99.

14. Schmidt Y. A., Kotina E. D., Kamyschanskaya I. G., Makarenko B. G. Application of radiomics criteria in the study of sarcopenia based on abdominal computed tomography data // Diagnostic Radiology and Radiotherapy. 2024. Vol. S(15). P. 195–196. Print 2079-5343.

15. Islam S., Kanavati F., Arain Z., Costa O. F. D., Crum W., Aboagye E. O., Rockall A. G. Fully-automated deep learning slice-based muscle estimation from CT images for sarcopenia assessment // Clinical Radiology. 2022. Vol. 77. N 5. P. e363–e371. <https://doi.org/10.1016/j.crad.2022.01.036>

16. Ha J., Park T., Kim H.-K., Shin Y., Ko Y., Kim D. W., Sung Y. S., Lee J., Ham S. J., Khang S., Jeong H., Koo K., Lee J., Kim K. W. Development of a fully automatic deep learning system for L3 selection and body composition assessment on computed tomography // Scientific Reports. 2021. Vol. 11. N 1. P. 21656. <https://doi.org/10.1038/s41598-021-00161-5>

17. Zwanenburg A., Leger S., Vallieres M., Löck S. Image biomarker standardisation initiative // arXiv preprint. arXiv: 1612.07003. 2016.

18. Löfstedt T., Brynolfsson P., Asklund T., Nyholm T., Garpebring A. Gray-level invariant Haralick texture features // PLoS One. 2019. Vol. 14. N 2. P. e0212110. <https://doi.org/10.1371/journal.pone.0212110>

Статья поступила в редакцию 17 мая 2024 г.

Статья принята к печати 25 июня 2024 г.

Контактная информация:

Шмидт Ян Александрович — магистрант; <https://orcid.org/0009-0001-0141-0517>, yanschmidt@mail.ru

Котина Елена Дмитриевна — д-р физ.-мат. наук, проф.; <https://orcid.org/0000-0002-2057-682X>, e.kotina@spbu.ru

Applying radiomics in computed tomography data analysis to predict sarcopenia

I. A. Schmidt, E. D. Kotina

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

For citation: Schmidt I. A., Kotina E. D. Applying radiomics in computed tomography data analysis to predict sarcopenia. *Vestnik of Saint Petersburg University. Applied Mathematics. Computer Science. Control Processes*, 2024, vol. 20, iss. 3, pp. 376–390. <https://doi.org/10.21638/spbu10.2024.306> (In Russian)

This article presents an algorithm implementing a radiomics approach to processing computed tomography (CT) data for diagnosing sarcopenia. The proposed method includes region of interest extraction, automatic muscle segmentation using deep learning models, extraction of radiomic features from CT-images, construction of correlation matrices, and selection of criteria for classification. The results show that the obtained radiomic parameters have a significant correlation with the presence of sarcopenia, allowing the construction of accurate classification models based on machine learning. This approach can significantly improve the diagnosis of sarcopenia, providing reliable non-invasive analysis methods.

Keywords: radiomics, texture analysis, machine learning, sarcopenia.

References

1. Chen Y.-C., Hsieh J.-W., Yang Y.-H., Lee C.-H., Yu P.-Y., Chen P.-Y., San A. S. Towards deep learning-based sarcopenia screening with body joint composition analysis. *2021 IEEE International Conference on Image Processing (ICIP)*. Anchorage, AK, USA, 2021, pp. 3807–3811. <https://doi.org/10.1109/ICIP42928.2021.9506482>

2. Chung H., Jo Y., Ryu D., Jeong C., Choe S. K., Lee J. Artificial-intelligence-driven discovery of prognostic biomarker for sarcopenia. *Journal of Cachexia Sarcopenia Muscle*, 2021, vol. 12, no. 6, pp. 2220–2230. <https://doi.org/10.1002/jcsm.12840>

3. Castillo-Olea C., Garcia-Zapirain S. B., Carballo L. C., Zuniga C. Automatic classification of

sarcopenia level in older adults: A case study at Tijuana General Hospital. *International Journal of Environmental Research and Public Health*, 2019, vol. 16, no. 18, p. 3275.

<https://doi.org/10.3390/ijerph16183275>

4. Ackermans L. L. G. C., Rabou J., Basrai M., Schweinlin A., Bischoff S. C., Cussenot O., Cancel-Tassin G., Renken R. J., Gomez E., Sanchez-Gonzalez P., Rainoldi A., Boccia G., Reisinger K. W., Bosch J. A. T., Blokhuis T. J. Screening, diagnosis and monitoring of sarcopenia: When to use which tool? *Clin. Nutr. ESPEN*, 2022, vol. 48, pp. 36–44. <https://doi.org/10.1016/j.clnesp.2022.01.027>

5. Xie H., Gong Y., Kuang J., Yan L., Ruan G., Tang S., Gao F., Gan J. Computed tomography-determined sarcopenia is a useful imaging biomarker for predicting postoperative outcomes in elderly colorectal cancer patients. *Cancer Research and Treatment*, 2020, vol. 52, no. 3, pp. 957–972.

<https://doi.org/10.4143/crt.2019.695>

6. Jalal M., Campbell J. A., Wadsley J., Hopper A. D. Computed tomographic sarcopenia in pancreatic cancer: Further utilization to plan patient management. *Journal of Gastrointest Cancer*, 2021 vol. 52, no. 3, pp. 1183–1187. <https://doi.org/10.1007/s12029-021-00672-4>

7. Smorchkova A. K., Petraikin A. V., Semenov D. S., Sharova D. E. Sarkopeniia: sovremennye podkhody k resheniiu diagnosticheskikh zadach [Sarcopenia: modern approaches to solving diagnosis problems]. *Digital Diagnostics*, 2022, vol. 3, no. 3, pp. 196–211. <https://doi.org/10.17816/DD110721> (In Russian)

8. Ueki H., Hara T., Okamura Y., Bando Y., Terakawa T., Furukawa J., Harada K., Nakano Y., Fujisawa M. Association between sarcopenia based on psoas muscle index and the response to nivolumab in metastatic renal cell carcinoma: A retrospective study. *Investig. Clin. Urol.*, 2022, vol. 63, no. 4, pp. 415–424. <https://doi.org/10.4111/icu.20220028>

9. Kim S., Kim T.-H., Jeong C.-W., Lee C., Noh S., Kim J. E., Yoon K.-H. Development of quantification software for evaluating body composition contents and its clinical application in sarcopenic obesity. *Scientific Reports*, 2020, vol. 10, art. no. 10452. <https://doi.org/10.1038/s41598-020-67461-0>

10. Chicklore S., Goh V., Siddique M., Roy A., Marsden P. K., Cook G. J. R. Quantifying tumour heterogeneity in 18F-FDG PET/CT imaging by texture analysis. *European Journal of Nuclear Medicine and Molecular Imaging*, 2012, vol. 40, no. 1, pp. 133–140. <https://doi.org/10.1007/s00259-012-2247-0>

11. Cook G., Siddique M., Taylor B., Yip C., Chicklore S., Goh V. Radiomics in PET: principles and applications. *Clinical and Translational Imaging*, 2014, vol. 2, no. 3, pp. 269–276. <https://doi.org/10.1007/s40336-014-0064-0>

12. Schmidt I., Kotina E., Buev P. Deep learning muscle segmentation model for CT images in DICOM format. *Cybernetics and Physics*, 2023, vol. 12, no. 3, pp. 201–206. <https://doi.org/10.35470/2226-4116-2023-12-3-201-206>

13. Shmidt I. A., Kotina E. D., Kamyshanskaya I. G., Makarenko B. G. Radiomika v issledovanii sarkopenii po KT izobrazheniiam [Radiomics in the study of sarcopenia using CT images]. *Diagnostic and Interventional Radiology*, 2024, vol. 18, no. S2.1, pp. 94–99. (In Russian)

14. Shmidt Y. A., Kotina E. D., Kamyshanskaya I. G., Makarenko B. G. Application of radiomics criteria in the study of sarcopenia based on abdominal computed tomography data. *Diagnostic Radiology and Radiotherapy*, 2024, vol. S(15), pp. 195–196. Print 2079-5343.

15. Islam S., Kanavati F., Arain Z., Costa O. F. D., Crum W., Aboagye E. O., Rockall A. G. Fully-automated deep learning slice-based muscle estimation 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>

16. Ha J., Park T., Kim H.-K., Shin Y., Ko Y., Kim D. W., Sung Y. S., Lee J., Ham S. J., Khang S., Jeong H., Koo K., Lee J., Kim K. W. Development of a fully automatic deep learning system for L3 selection and body composition assessment on computed tomography. *Scientific Reports*, 2021, vol. 11, no. 1, p. 21656. <https://doi.org/10.1038/s41598-021-00161-5>

17. Zwanenburg A., Leger S., Vallieres M., Löck S. Image biomarker standardisation initiative. *arXiv preprint*, arXiv: 1612.07003. 2016.

18. Löfstedt T., Brynolfsson P., Asklund T., Nyholm T., Garpebring A. Gray-level invariant Haralick texture features. *PLoS One*, 2019, vol. 14, no. 2, p. e0212110. <https://doi.org/10.1371/journal.pone.0212110>

Received: May 17, 2024.

Accepted: June 25, 2024.

Authors' information:

Ian A. Schmidt — Master Student; <https://orcid.org/0009-0001-0141-0517>, yanschmidt@mail.ru

Elena D. Kotina — Dr. Sci. in Physics and Mathematics, Professor;
<https://orcid.org/0000-0002-2057-682X>, e.kotina@spbu.ru