DOI: 10.47407/kr2026.7.09.00p4562

Модели машинного обучения в диагностике саркопении с использованием данных компьютерной томографии: обзор литературы

О.Э. Табакчи✉, Д.Д. Мухаметова, Д.И. Абдулганиева

ФГБОУ ВО «Казанский государственный медицинский университет» Минздрава России, Казань, Россия
✉*olya-akchurina@mail.ru*

Аннотация
Данный обзор посвящен современным подходам к диагностике саркопении с использованием компьютерной томографии (КТ) и методов машинного обучения (ML). Саркопения, прогрессирующее снижение мышечной массы и силы, признана серьезным осложнением многих хронических заболеваний, увеличивающим риск осложнений и смертности. Традиционная диагностика ограничена субъективностью и трудоемкостью ручных измерений. КТ, выполняемая по различным клиническим показаниям, стала ключевым инструментом для объективной оценки как количества (площадь мышц, индекс SMI), так и качества (плотность в единицах Хаунсфилда) мышечной ткани, преимущественно на уровне третьего поясничного позвонка (L3). Для автоматизации анализа и повышения точности активно разрабатываются ML-модели, в частности методы радиомики и глубокого обучения. Радиомика позволяет извлекать сотни количественных признаков из изображений, отражающих текстуру и неоднородность мышц, в то время как сверхточные нейронные сети решают задачи автоматической сегментации мышц и прямой классификации. Клинические исследования демонстрируют высокую эффективность таких моделей в прогнозировании исходов при онкологических, гастроэнтерологических, гепатологических и других заболеваниях, часто превосходя традиционные методы. Однако внедрению в рутинную практику мешают отсутствие стандартизации пороговых значений, вариабельность протоколов КТ, проблема интерпретируемости моделей («черный ящик») и нехватка крупных размеченных датасетов. Перспективы связаны с разработкой стандартов, интеграцией автоматических инструментов в рабочие станции радиологов и проведением проспективных исследований для доказательства клинической пользы.
Ключевые слова: саркопения, компьютерная томография, машинное обучение, искусственный интеллект.
Для цитирования: Табакчи О.Э., Мухаметова Д.Д., Абдулганиева Д.И. Модели машинного обучения в диагностике саркопении с использованием данных компьютерной томографии: обзор литературы. *Клинический разбор в общей медицине*. 2026; 7 (9): 48–52. DOI: 10.47407/kr2026.7.09.00p4562

Machine learning models in the diagnosis of sarcopenia using computed tomography: a literature review

Olga E. Tabakchi✉, Dilyara D. Mukhametova, Diana I. Abdulganieva

Kazan State Medical University, Kazan, Russia
✉*olya-akchurina@mail.ru*

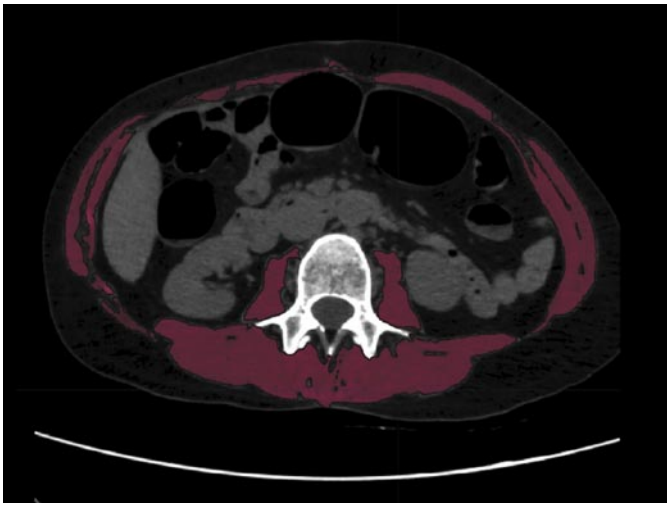
Abstract
This review focuses on modern approaches to diagnosing sarcopenia using computed tomography (CT) and machine learning (ML) methods. Sarcopenia, a progressive decline in muscle mass and function, is recognized as a serious complication of many chronic diseases that increases the risk of complications and mortality. Traditional diagnosis is limited by the subjectivity and labor-intensiveness of manual measurements. CT, performed for various clinical indications, has become a key tool for the objective assessment of both the quantity (muscle area, skeletal muscle index – SMI) and quality (density in Hounsfield units) of muscle tissue, predominantly at the level of the third lumbar vertebra (L3). To automate analysis and improve accuracy, ML models, specifically radiomics and deep learning methods, are being actively developed. Radiomics allows for the extraction of hundreds of quantitative features from images reflecting muscle texture and heterogeneity, while convolutional neural networks solve the tasks of automatic muscle segmentation and direct classification. Clinical studies demonstrate the high efficacy of such models in predicting outcomes in oncological, gastroenterological, hepatological, and other diseases, often outperforming traditional methods. However, implementation into routine practice is hindered by the lack of standardized cut-off values, variability in CT protocols, the problem of model interpretability (the "black box" issue), and a shortage of large annotated datasets. Future prospects are associated with the development of standards, the integration of automated tools into radiologists' workstations, and the conduction of prospective studies to prove clinical utility.
Keywords: sarcopenia, computed tomography, machine learning, artificial intelligence.
For citation: Tabakchi O.E., Mukhametova D.D., Abdulganieva D.I. Machine learning models in the diagnosis of sarcopenia using computed tomography: a literature review. *Clinical review for general practice*. 2026; 7 (9): 48–52 (In Russ.). DOI: 10.47407/kr2026.7.09.00p4562

Введение

Саркопения, определяемая как прогрессирующее и генерализованное снижение массы, силы и функциональной способности скелетных мышц, признана самостоятельным заболеванием с серьезными клиническими последствиями. Она ассоциируется с повышением риска падений, функциональной зависимости, послеоперационных осложнений, снижением эффективности и переносимости терапии, а также с увеличением общей смертности [1, 2]. Изначально рассматриваемая в контексте старения, сегодня саркопения признана осложнением широкого спектра хронических заболеваний, включая онкологические, гастроэнтерологические, метаболические и кардиологические заболевания, что делает ее актуальной междисциплинарной проблемой [3, 4].

Традиционная диагностика, основанная на консенсусах Европейской рабочей группы по саркопении у пожилых людей – EWGSOP2 и Азиатской рабочей группы по саркопении – AWGS, опирается на оценку мышечной силы (например, сила хвата кисти), физической работоспособности (например, тест скорости ходьбы) и массы скелетных мышц [1, 5]. Однако именно количественная оценка мышечной массы долгое время оставалась наиболее методически сложным звеном в клинической практике. В этом контексте методы медицинской визуализации, в первую очередь компьютерная томография (КТ), приобретают решающее значение, выступая в роли объективного и воспроизводимого инструмента. КТ, выполняемая в рутинном порядке по множеству клинических показаний (стадирование рака, оценка заболеваний печени, диагностика в абдоминальной хирургии), содержит детальную информацию о площади, объеме и, что особенно важно, о качестве скелетной мускулатуры [6].

Пример ручной сегментации КТ-изображения на уровне L3.
Example of the CT image manual segmentation at the L3 level.



Источник: личный архив авторов.

КТ–признаки саркопении: параметры измерения

Ключевым анатомическим ориентиром для количественной оценки служит одиночный аксиальный срез на уровне третьего поясничного позвонка (L3). На этом уровне визуализируются основные мышечные группы живота и спины: большая поясничная, параспинальные (разгибатели спины), а также мышцы брюшной стенки (прямые, наружные и внутренние косые, поперечная). Площадь всех этих мышц, измеренная в квадратных сантиметрах (см^2), является первичным и наиболее распространенным показателем. Для нивелирования влияния антропометрических различий между пациентами площадь нормализуют, чаще всего деля на квадрат роста, получая индекс скелетной мышечной массы (Skeletal Muscle Index – SMI, см^2/м^2) [7]. Альтернативным индексом является PMI (Psoas Muscle Index), учитывающий только площадь большой поясничной мышцы [8]. Пороговые значения для диагностики саркопении варьируются в зависимости от популяции, пола и этнической принадлежности. Например, в онкологии широко применяются пороги SMI<41 см^2/м^2 для женщин и <43 см^2/м^2 для мужчин с индексом массы тела (ИМТ) <25, и <53 см^2/м^2 для мужчин с ИМТ ≥25 [7]. Однако помимо количественного параметра – площади – качественный аспект, оцениваемый по плотности ткани в единицах Хаунсфилда (HU), не менее важен. Средняя плотность мышц отражает степень внутримышечной жировой инфильтрации (миостеатоза). Здоровая мышечная ткань имеет плотность в районе от +30 до +150 HU. Снижение средней плотности ниже +30 HU является независимым предиктором слабости, инсулинорезистентности и смертности, даже при формально сохраненной площади мышц, подчеркивая важность комплексной оценки «количества» и «качества» мышц [9, 10].

Ручная сегментация мышечных контуров на каждом КТ-срезе – процесс кропотливый, требующий высокой квалификации и занимающий в среднем 10–15 мин на одного пациента (а при сложной анатомии или низком качестве изображения – и больше), что делает его непрактичным для рутинного скрининга в условиях высокой клинической нагрузки [11] (см. рисунок). Именно это ограничение стало катализатором для активного внедрения методов искусственного интеллекта, в частности машинного обучения (Machine Learning – ML) и радиомики, целью которых является полная или частичная автоматизация процесса анализа и извлечения новых, клинически значимых прогностических признаков.

Чтобы понять потенциал этих методов, полезно рассмотреть их в сравнении с другими методами визуализации, применяемыми для оценки мышечной массы. Золотым стандартом в научных исследованиях долгое время считалась магнитно-резонансная томография, обеспечивающая превосходную контрастность мягких тканей без ионизирующего излучения и позволяющая точно дифференцировать мышечную ткань от жировой [12]. Однако высокая стоимость, длительность сканирования, ограничения, связанные с наличием металлических имплантатов или кардиостимуляторов, а также клаустрофобия у пациентов и, что критически важно для ML, значительное разнообразие протоколов и последовательностей (T1-, T2-взвешенные, Dixon и др.) создают серьезные препятствия для создания крупных, стандартизированных датасетов, необходимых для обучения надежных алгоритмов. Ультразвуковое исследование (УЗИ) – портативный, безопасный и относительно недорогой метод, позволяющий оценить толщину мышц и эхогенность (косвенный показатель жировой инфильтрации) [13]. Его основной недостаток – высокая операторозависимость: результаты сильно варьируются в зависимости от положения датчика, приложенного давления и навыков специалиста. Эта вариабельность делает УЗИ сложной мишенью для разработки универсальных автоматизированных ML-алгорит-

мов, применимых в разных медицинских центрах. Двухэнергетическая рентгеновская абсорбциометрия и биоимпедансный анализ широко используются в клинической практике благодаря доступности, но они в основном предоставляют лишь интегральную (обобщенную) оценку безжировой массы, не дифференцируя отдельные мышечные группы и не давая информации о внутримышечном жире [1, 14]. В этом контексте КТ занимает уникальную нишу. Во-первых, это «попутный» метод: огромный объем сканов ежедневно выполняется по клиническим показаниям. Во-вторых, протоколы КТ брюшной полости и таза относительно стандартизированы в глобальном масштабе. В-третьих, КТ предоставляет абсолютные количественные данные в единицах Хаунсфилда, что идеально подходит для точных измерений и математического анализа. Именно эти характеристики делают КТ основным источником данных для внедрения ML-методов в диагностику саркопении. Согласно современным клиническим консенсусам (например, EWGSOP2), КТ рассматривается как эталонный (золотой стандарт) метод для точного количественного определения мышечной массы в исследовательских целях.

Применение ML-методов в клинической практике

Клиническая эффективность и прогностическая ценность ML-методов на основе КТ наиболее убедительно продемонстрированы в онкологии, где саркопения является независимым фактором риска нежелательных последствий лечения, послеоперационных осложнений и снижения общей выживаемости. Например, в исследовании van Dijk и соавт. у пациентов с раком поджелудочной железы низкая мышечная плотность (показатель качества мышц) и высокая висцеральная жировая масса, определенные по КТ, были независимо ассоциированы с худшей общей выживаемостью и повышенным риском хирургических инфекций места операции [15]. В другом исследовании, модель Random Forest, обученная на радиомических признаках, показала точность 0,88±0,04 и AUC 0,93±0,04 в прогнозировании прогрессирования болезни [16]. Примечательно, что в этом же исследовании традиционный ручной показатель – индекс поясничной мышцы (PMI) – не показал статистически значимой связи с прогрессированием заболевания (*p*-значения от 0,277 до 0,465) [16]. Этот контраст подчеркивает, что современные вычислительные методы способны выявлять сложные паттерны, упускаемые при стандартных антропометрических измерениях, и предоставлять более точный прогноз. Прогностическая сила моделей, основанных на оценке мышц, подтверждается и в гематологии. У пациентов с диффузной В-крупноклеточной лимфомой прогностические номограммы, включающие радиомические признаки, надежно стратифицируют больных на группы низкого и высокого риска [17].

В гепатологии и трансплантологии печени саркопения – хорошо известный предиктор декомпенсации цирроза, печеночной недостаточности и смертности как до, так и после трансплантации. Ручные измерения SMI требовали значительного времени. Внедрение автоматизированного фреймворка (AutoMATiCA), описанного M. Paris и соавт., позволило анализировать большую базу снимков, показывая высокую точность сегментации с ручным методом (коэффициент сходства Дайса для скелетной мускулатуры составил 0,983±0,013) [18]. КТ-диагностика саркопении (SMI) должна стать рутинной практикой при оценке пациентов с циррозом, так как она независимо прогнозирует исходы, а раннее вмешательство может улучшить состояние пациентов до и после трансплантации печени [19]. У пациентов с воспалительными заболеваниями кишечника саркопения ассоциируется с более агрессивным течением болезни, частыми госпитализациями и неэффективностью биологической терапии. Исследование T. Zhang и соав. показало, что КТ-диагностированная саркопения является независимым прогностическим фактором тяжелых осложнений после резекции кишечника по поводу болезни Крона, с отношением шансов (OR) до 3,97 [20].

Эффективность ML-моделей в диагностике саркопении

Точность диагностики саркопении с использованием ML-методов на основе КТ-изображений существенно варьирует в зависимости от типа алгоритма, что отражается в широком диапазоне значений площади под ROC-кривой (AUC) – от 0,636 до 0,990 (см. таблицу). Эта вариабельность подчеркивает важность выбора оптимальной модели для конкретной клинической задачи и популяции пациентов. Алгоритмы, основанные на кластеризации, демонстрируют как очень высокие, так и умеренные результаты. Например, в исследовании, использующем метод Оцу для обработки КТ-изображений, была достигнута AUC 0,986 на обучающей выборке и 0,958 на валидационной, тогда как модель на основе гауссовских смесей (GMM) показала еще более высокую точность на обучении – AUC 0,990, хотя на валидации ее эффективность несколько снизилась до 0,903 [21]. В противоположность этому, алгоритм K-средних (K-means, метод кластеризации, разделяющий данные на группы по схожести признаков) в той же работе оказался менее стабильным, с AUC 0,727 при обучении и 0,772 при валидации [21]. Эти данные указывают на то, что даже в рамках одного класса методов их диагностическая ценность может быть неоднородной.

Контролируемые методы обучения показывают стабильно высокую эффективность. Модель Random Forest, примененная для анализа радиомических признаков у пациентов с раком желудка и пищевода, продемонстрировала точность с AUC 0,96±0,02 и общей точностью классификации 90% [16]. Это делает ее одним из наиболее надежных инструментов для данной группы пациентов. Для пациентов с воспалительными заболеваниями кишечника, в частности с болезнью Крона, наилучшие результаты показала модель LightGBM,

Сравнение эффективности ML-моделей в диагностике саркопении на примере некоторых исследований
Comparison of ML-model efficiency in the diagnosis of sarcopenia exemplified by certain studies

Исследование	Тип модели	AUC	Чувствительность	Специфичность
Huayan Zuo et al., 2025 [21]	CT-Otsu	Обучение: 0,986, Валидация: 0,958	–	–
Huayan Zuo et al., 2025 [21]	CT-GMM	Обучение: 0,990, Валидация: 0,903	–	–
Daniel Vogele et al., 2024 [16]	Random Forest	0,96±0,02	–	–
Ye Ma et al., 2025 [22]	Nomogram	0,951 (95% CI: 0,886–1,000)	–	100%
Y. Tseng et al., 2023 [23]	LightGBM	0,933	72,7%	87,0%
Shangzhi Gu et al., 2023 [24]	Auto SMI model	0,874	71,8%	87,6%
Fanghu Wang et al., 2024 [17]	SVM	0,862	79,2%	83,3%
Yoon Seong Lee et al., 2020 [25]	3D U-Net	0,858 (95% CI: 0,815–0,901)	–	–
Xiaodong Chen et al., 2022 [26]	Radiomics	Обучение: 0,795, Валидация: 0,825	–	–
V. Soria-Utrilla et al., 2024 [27]	AI-assisted CT	0,82 (95% CI: 0,77–0,87)	77%	72,7%
Huayan Zuo et al., 2025 [21]	CT-K-means	Обучение: 0,727, Валидация: 0,772	–	–
P. Pickhardt et al., 2022 [28]	Deep learning	L1: 0,737, L3: 0,721	–	–
J. J. López-Gómez et al., 2025 [29]	U-Net	0,628-0,636	–	–

Примечание: AUC (Area Under the Curve) – площадь под ROC-кривой; Auto SMI model (Automated Skeletal Muscle Index model) – автоматизированная модель расчета индекса скелетной мускулатуры; CI (Confidence Interval) – доверительный интервал; CT (Computed Tomography) – КТ; CT-GMM (Computed Tomography – Gaussian Mixture Model) – КТ с использованием модели гауссовских смесей (для сегментации); CT-K-means (Computed Tomography – K-means clustering) – КТ с использованием кластеризации методом k-средних (для сегментации); CT-Otsu (Computed Tomography – Otsu's method) – КТ с использованием метода Отсу (для пороговой сегментации); LightGBM (Light Gradient Boosting Machine) – легкая градиентная бустинговая машина (алгоритм машинного обучения); ML (Machine Learning) – машинное обучение; Random Forest – случайный лес (алгоритм машинного обучения); SVM (Support Vector Machine) – метод опорных векторов (алгоритм машинного обучения); 3D U-Net – трехмерная U-образная сверточная нейронная сеть (архитектура для сегментации изображений).

которая достигла AUC 0,933 при чувствительности 72,7% и специфичности 87,0% [23]. Высокая специфичность означает, что модель достаточно точно исключает пациентов без саркопении, что важно для предотвращения гипердиагностики.

Модели глубокого обучения, предназначенные для автоматической сегментации мышц и расчета индексов, также подтвердили свою клиническую состоятельность. Исследование S. Onishi и соавт. продемонстрировало низкую воспроизводимость ручных измерений: коэффициенты согласия каппа составили лишь 0,478 и 0,236 для тестовой и валидационной групп соответственно, а при повторной оценке диагноз менялся в 43% случаев [30]. Алгоритм 3D U-Net для автоматической сегментации мышц и расчета SMI позволил достичь AUC 0,858 в диагностике саркопении, что обеспечивает надежную основу для прогностической способности рассчитанного SMI для выявления клинической саркопении [31]. Автоматизированная система на основе искусственного интеллекта для диагностики саркопении, включающая модель классификации срезов (EfficientNetV2) и модель сегментации областей (U-Net), продемонстрировала высокую точность: 97,5% в идентификации среза L3 и 92% в сегментации областей скелетных мышц, подкожного и висцерального жира [32]. Важно отметить, что автоматизация процесса не только повышает эффективность, но и устраняет существенный недостаток ручных методов – высокую межоператорскую вариабельность и субъективность, которые могут приводить к расхождениям в диагнозе при повторных измерениях.

Перспективы и вызовы внедрения ML в рутинную практику диагностики саркопении

Несмотря на впечатляющий прогресс, путь от исследовательской модели к рутинному клиническому инструменту сопряжен с серьезными вызовами.

Ключевой проблемой остается отсутствие единых стандартов. Существует вариабельность в выборе анатомического уровня (L3, Th12, середина бедра), методах нормализации (рост^2, рост, площадь поверхности тела) и, что наиболее важно, в пороговых значениях для разных популяций и заболеваний [33]. Модель, обученная на порогах для онкологических пациентов европеоидной расы, может давать систематическую ошибку при применении к азиатской популяции с гепатологическими заболеваниями.

Другой вызов – проблема «черного ящика», особенно свойственная сложным моделям глубокого обучения. Врачу-клиницисту сложно доверять решению, которое невозможно объяснить. Если модель предсказывает высокий риск послеоперационного осложнения, но не может указать, какие именно особенности изображения к этому привели, это затрудняет принятие клинических решений. Методы объяснимого искусственного интеллекта (XAI), такие как SHAP и LIME, начинают решать эту проблему, визуализируя области изображения, наиболее повлиявшие на прогноз [34].

Наконец, существует острая нехватка крупных, многоцентровых, мультиэтнических и мультисканерных размеченных датасетов, необходимых для обучения устойчивых моделей. Процесс ручной сегментации экспертом трудоемок и дорог, создавая «бутылочное горлышко» (основное препятствие) для развития исследований, так как требует значительных временных и экспертных ресурсов [35].

Заключение

Таким образом, синергия КТ и ML открывает новую эру в объективной, количественной и прогностической диагностике саркопении. Превращая рутинные КТ-изображения в богатый источник данных о составе тела, эти технологии позволяют выявлять пациентов группы высокого риска, ранее остававшихся вне поля зрения клиницистов. Несмотря на сохраняющиеся вызовы, связанные со стандартизацией, обобщаемостью и интерпретируемостью моделей, темпы технологического прогресса и растущее понимание клинической значимости саркопении дают основания полагать, что в ближайшем будущем автоматизированный анализ мышечного статуса станет неотъемлемой частью протокола обработки КТ-исследований, способствуя переходу к более персонализированной и превентивной медицине.

Конфликт интересов. Авторы заявляют об отсутствии конфликта интересов.
Conflict of interests. The authors declare that there is not conflict of interests.

Благодарности. Исследование поддержано грантом Международного научного совета для молодых ученых Казанского государственного медицинского университета.
Acknowledgments. The study was supported by a grant from the International Scientific Council for Young Scientists of Kazan State Medical University.

Список литературы доступен на сайте журнала https://klin-razbor.ru/
The list of references is available on the journal's website https://klin-razbor.ru/

ИНФОРМАЦИЯ ОБ АВТОРАХ

Табакчи Ольга Эриковна – аспирант каф. госпитальной терапии, ФГБОУ ВО «Казанский ГМУ». E-mail: olya-akchurina@mail.ru; Scopus Author ID: 59712794100; SPIN-код: 5036-4415; ORCID: 0009-0009-5739-7807

Мухаметова Диляра Дамировна – канд. мед. наук, доц. каф. госпитальной терапии, ФГБОУ ВО «Казанский ГМУ». Scopus Author ID: 56667695500; SPIN-код: 7998-5365; ORCID: 0000-0003-2102-0142

Абдулганиева Диана Ильдаровна – д-р мед. наук, проф., зав. каф. госпитальной терапии, ФГБОУ ВО «Казанский ГМУ». Scopus Author ID: 39161040600; SPIN-код: 6676-4270; ORCID: 0000-0001-7069-2725

Поступила в редакцию: 26.03.2026
Поступила после рецензирования: 27.03.2026
Принята к публикации: 30.04.2026

INFORMATION ABOUT THE AUTHORS

Olga E. Tabakchi – Graduate Student, Kazan State Medical University. E-mail: olya-akchurina@mail.ru; Scopus Author ID: 59712794100; SPIN-код: 5036-4415; ORCID: 0009-0009-5739-7807

Dilyara D. Mukhametova – Cand. Sci. (Med.), Assoc. Prof., Kazan State Medical University. Scopus Author ID: 56667695500; SPIN-код: 7998-5365; ORCID: 0000-0003-2102-0142

Diana I. Abdulganieva – Dr. Sci. (Med.), Prof., Head of the Department of hospital therapy, Kazan State Medical University. Scopus Author ID: 39161040600; SPIN-код: 6676-4270; ORCID: 0000-0001-7069-2725

Received: 26.03.2026
Revised: 27.03.2026
Accepted: 30.04.2026