

Прогнозирование нутритивной недостаточности у онкологических пациентов с помощью машинного обучения: обзор

М.Ю. Кукош^{1,2}, О.А. Обухова³

¹ Российский университет дружбы народов им. П. Лумумбы, Москва, Россия;

² Медицинский радиологический научный центр им. А.Ф. Цыба — филиал Национального медицинского исследовательского центра радиологии, Обнинск, Россия;

³ Национальный медицинский исследовательский центр онкологии им. Н.Н. Блохина, Москва, Россия

АННОТАЦИЯ

Нутритивная недостаточность оказывает значительное влияние на результаты противоопухолевого лечения онкологических больных. Достаточно часто назначение нутритивной поддержки врач осуществляет субъективно, в связи с чем возможны ошибки при принятии решения о необходимости проведения, способе введения и составе искусственного питания. В то же время в реальной клинической практике всё чаще применяют машинное обучение и искусственный интеллект, однако их применение в области нутритивной поддержки весьма ограничено. Мы провели обзор литературы, посвящённой этой теме, с целью освящения современного состояния проблемы.

Приведены и проанализированы публикации, проиндексированные в базах данных MEDLINE, Web of Science, Научная электронная библиотека (eLibrary) за 2021–2024 гг. о применении искусственного интеллекта, а именно алгоритмов машинного обучения для раннего выявления белково-энергетической недостаточности и прогнозирования её развития у онкологических пациентов. Результаты показывают, что предиктивные модели на основе искусственного интеллекта, а также модели для выявления белково-энергетической недостаточности могут быть интегрированы в системы поддержки принятия врачебных решений. Это обеспечивает своевременную диагностику и коррекцию нутритивного дефицита, что позволяет избежать субъективности и ограничений, присущих традиционному "эмпирическому" подходу к назначению нутритивной поддержки. В работе рассмотрены ошибки, часто встречающиеся при реализации нутритивной поддержки в онкологической практике, а также предложены возможности для их нивелирования с помощью машинного обучения.

По результатам проведённого анализа видно, что, несмотря на масштабные перспективы, использование инструментов машинного обучения и искусственного интеллекта в процессе выявления нутритивного дефицита и осуществления нутритивной поддержки в реальной клинической практике пока очень ограничено.

Ключевые слова: машинное обучение, искусственный интеллект, нутритивная поддержка, нутритивная недостаточность, рак, онкология.

КАК ЦИТИРОВАТЬ:

Кукош М.Ю., Обухова О.А. Прогнозирование нутритивной недостаточности у онкологических пациентов с помощью машинного обучения: обзор // Клиническое питание и метаболизм. 2025. Т. 6, № 1. С. XX-XX. DOI: [10.17816/clinutr686579](https://doi.org/10.17816/clinutr686579) EDN: DFBYCE

Рукопись получена: 02.07.2025

Рукопись одобрена: 27.08.2025

Опубликована online: 12.09.2025

Статья доступна по лицензии [CC BY-NC-ND 4.0 International](https://creativecommons.org/licenses/by-nc-nd/4.0/) License.

© Эко-Вектор, 2025

Changing the methodology for predicting nutritional deficiency in cancer patients in the context of rapid development of machine learning in medicine: review

Mariya Yu. Kukosh^{1,2}, Olga A. Obukhova³

¹ Peoples' Friendship University of Russia, Moscow, Russia;

² A.F. Tsyb Medical Radiological Research Center — branch of the National Medical Research Radiological Center, Obninsk, Russia;

³ National Medical Research Center of Oncology named after N.N. Blokhin, Moscow, Russia

ABSTRACT

Nutritional deficiency has a significant impact on the results of antitumor treatment of cancer patients. Quite often, the appointment of nutritional support is subjective, which may lead to errors in deciding on the need for, type and composition of artificial nutrition. At the same time, machine learning and artificial intelligence, the use of which in the field of nutritional support is very limited, are increasingly being introduced into real clinical practice. We conducted a review of the literature on this topic in order to highlight the current state of the problem. The paper presents and analyzes literary data from the medical databases PubMed, Web of Science, e-Library (2021-2024) on the use of artificial intelligence, namely machine learning algorithms for the early detection of protein-energy deficiency and prediction of its development in cancer patients. It is shown that predictive models based on artificial intelligence, as well as models for identifying protein-energy malnutrition, can be integrated into systems to support medical decision-making, ensuring its timely diagnosis and correction, which will avoid subjectivity and limitations inherent in the traditional, "empirical" approach to prescribing nutritional support. The errors that are often encountered in the implementation of nutritional support in oncological practice are considered, and opportunities for their leveling using machine learning are proposed.

Based on the results of the analysis, it is clear that, despite large-scale prospects, the use of machine learning and artificial intelligence tools in the process of identifying nutritional deficiency and implementing nutritional support in real clinical practice is still very limited.

Keywords: machine learning, artificial intelligence, nutritional support, nutritional deficiency, cancer, oncology

TO CITE THIS ARTICLE:

Kukosh MYu, Obukhova OA. Changing the methodology for predicting nutritional deficiency in cancer patients in the context of rapid development of machine learning in medicine: review. *Clinical nutrition and metabolism*. 2025;6(1):XX–XX. DOI: [10.17816/clinutr686579](https://doi.org/10.17816/clinutr686579) EDN: DFBYCE

Received: 02.07.2025

Accepted: 27.08.2025

Published online: 12.09.2025

The article can be used under the CC BY-NC-ND 4.0 International License

© Eco-Vector, 2025

ВВЕДЕНИЕ

Новейшая технологическая революция охватила все сферы человеческой деятельности. Знаменательной приметой нашего времени стала интеграция искусственного интеллекта (ИИ), использующего большие объёмы данных, алгоритмы машинного обучения (МО) и так называемую «предиктивную аналитику», в клиническую медицину [1–4]. В силу новизны проблемы представляет интерес взаимодействия человеческого интеллекта и ИИ, а также оценка будущей синергии, которая потенциально может качественно изменить организацию клинического питания (КП).

Традиционный подход к принятию врачебных решений представляет собой «эмпирический подход». Он объединяет клинический опыт, наблюдения и общие рекомендации. Безусловно, этот подход субъективен и зачастую отличается предвзятостью.

Врач оценивает функциональное состояние пациента с помощью различных инструментов: шкалы Карновского и шкалы ECOG/WHO PS (The Eastern Cooperative Oncology Group/World Health Organization Performance Status, шкала оценки тяжести состояния пациента по версии Восточной кооперативной онкологической группы/Всемирной организации здравоохранения) [5, 6]. Он также учитывает нозологическую форму, «нутритивные барьеры», сопутствующие заболевания, вид и объём противоопухолевого лечения. На основании своего опыта врач проводит диетологическое консультирование и назначает нутритивную поддержку (НП). В идеале такой подход гибкий и максимально учитывает индивидуальные особенности пациента. Однако он может носить субъективный характер и далеко не всегда опирается на актуальные научные данные. К тому же, качество принятия решений напрямую зависит от компетенций врача-онколога в тематике НП и может быть ими ограничено [7]. Также врач может испытывать трудности в определении белково-энергетической недостаточности (БЭН), необходимой для расчета корректной НП, даже используя предлагаемые скрининговые шкалы (Nutritional Risk Screening 2002, NRS 2002; Malnutrition Universal Screening Tool, MUST; рекомендации Европейского общества медицинской онкологии 2008 г., ESMO 2008).

По нашим наблюдениям, самыми распространёнными ошибками при реализации НП в онкологической практике являются: игнорирование факта наличия БЭН у онкологического пациента, назначение КП без учёта возможностей организма по его усвоению, неоптимальный выбор точки доступа для проведения КП, неадекватный разовый/суточный объём вводимого КП, замена КП неоптимальным или неэффективным аналогами, таким как детское или спортивное питание.

Адекватное внедрение искусственного интеллекта (ИИ) в реальную клиническую практику позволит исключить отрицательные стороны эмпирического подхода. Если рассматривать организацию НП с точки зрения методологического процесса, то на каждой стадии её реализации можно применять систему поддержки принятия решений на базе ИИ (рис. 1.). Перспективы применения ИИ для оптимизации НП очень благоприятные. Хотя эта область только развивается, новые технологии внедряют так быстро, что их массовое использование в клиниках начнётся в ближайшем будущем.

Два года назад эксперты снова не смогли сформулировать единые рекомендации по клиническому питанию (КП) для отделений интенсивной терапии. Данные клинических исследований вновь оказались противоречивыми, и пришлось оставить формулировку о том, что решение должен принимать врач индивидуально в каждом случае («case by case») [8]. Однако, скорее всего, в последующих рекомендациях эта фраза изменится коренным образом: за несколько месяцев до цитируемой работы её первый автор, ведущий эксперт Европейского общества клинического питания и метаболизма (ESPEN), уверенно заявил, что в ближайшей перспективе персонализированное назначение питания будет основываться на прогнозе и рекомендациях, основанных на результатах МО [9]. Уже к концу 2024 года исследователи предложили более 10 моделей, разработанных на основе МО, для прогнозирования непереносимости энтерального питания в интенсивной терапии [10].

В этом небольшом обзоре мы проследим, как менялись методы математического анализа для краткосрочного (как правило, до 3 мес., редко до 6 мес.) прогнозирования недостаточности питания у онкологических пациентов во время лечения. Прогноз нутритивной недостаточности в клиническом питании представляет собой естественный и необходимый этап, непосредственно определяет вариант, объём и длительность НП. МО позволяет не только использовать накопленные объёмы клинических данных, но и применять для построения прогностических

моделей математические методы, слишком трудоёмкие для расчёта человеком, даже с использованием компьютера.

ЭВОЛЮЦИЯ ДИАГНОСТИКИ НУТРИТИВНОЙ НЕДОСТАТОЧНОСТИ: ОТ СКРИНИНГОВЫХ ШКАЛ ДО ПРОГНОСТИЧЕСКИХ МОДЕЛЕЙ

Традиционно для прогноза недостаточности питания у онкологических пациентов используют скрининговые шкалы. В настоящее время используют несколько таких шкал с различающимися критериями оценки недостаточности питания: NRS 2002 (Nutritional Risk Screening, шкала нутриционного риска, основывается на критериях MUST (Malnutrition Universal Screening Tool, шкала оценки недостаточности питания)), PG-SGA (Patient Generated Subjective Global Assessment, субъективная глобальная оценка) и GLIM (Global Leadership Initiative on Malnutrition, Глобальный консенсус по проблемам неполноценного питания).

Экспертные консенсусные решения привели к созданию минимального набора стандартизированных критериев, которые специалисты могут применять на масштабных контингентах в рамках существующих ресурсов здравоохранения, нашедших отражение в скрининговой шкале NRS 2002 (Nutritional Risk Screening, шкала нутриционного риска) [11]. Цель применения шкалы NRS 2002 — выявление белково-энергетической недостаточности (БЭН) и риск её развития в условиях стационара. Эта скрининговая шкала содержит критерии шкалы MUST, включая оценку тяжести заболевания, так как в этом состоянии организму необходимо больше питательных веществ. Шкала содержит четыре вопроса в качестве предскрининга для стационарных отделений с небольшим количеством пациентов, имеющих потенциальный риск БЭН. Согласно шкале NRS 2002, люди старше 70 лет входят в группу риска по БЭН. Рекомендации по применению данной шкалы для оценки риска недостаточного питания опубликованы в практических рекомендациях RUSSCO (Российское общество клинической онкологии) [12].

Следующий инструмент — шкала PG-SGA (Patient Generated Subjective Global Assessment, субъективная глобальная оценка). Данная скрининговая шкала служит инструментом для оценки состояния питания онкологических больных и прогнозирования послеоперационных осложнений, отражающих тяжесть заболевания [13]. Шкала PG-SGA состоит из двух объёмных модулей. Первый модуль представляет собой опросник, в котором пациент фиксирует динамику массы тела, изменения в потреблении пищи, наличие «нутритивных барьеров» и уровень физической активности. Второй модуль заполняет медицинский работник, оценивая функциональный статус и физическую форму пациента, его мышечную силу и потери жировой ткани. Каждый признак оценивают отдельно, затем полученные баллы суммируют в единый балл, ранжируемый от 0 до 35. О наличии БЭН можно говорить, начиная с 4 баллов, и чем выше балл, тем тяжелее БЭН.

Применение PG-SGA в реальной клинической практике ограничено сложностями работы с этой шкалой, субъективность отдельных факторов, значительные затраты времени и усилий со стороны медицинских работников. Кроме того, ряд экспертов указывают на потенциальные проблемы с точностью шкалы, которые усугубляются отсутствием достаточных данных доказательной медицины для подтверждения её прогностической надёжности. Всё это ограничивает значение PG-SGA в глазах клиницистов [13].

В клинической медицине получила распространение относительно новая шкала оценки БЭН GLIM (табл. 1). Исследователи валидировали её, в том числе, для онкологических пациентов [14, 15].

Она представляет собой двухэтапный подход к диагностике БЭН: первичный скрининг для присвоения статуса «группы риска» с использованием любого достоверного инструмента скрининга, а второй этап — более детальная оценка для диагностики и определения степени тяжести недостаточности питания. В пятёрку критериев, которые получили наивысшие оценки экспертов, вошли три фенотипических критерия (непроизвольная потеря веса, низкий индекс массы тела (ИМТ) и снижение мышечной массы) и два этиологических критерия (снижение потребления или усвоения пищи, а также наличие воспалительной реакции или тяжесть заболевания). Для постановки диагноза нутритивной недостаточности необходимо наличие, по крайней мере, одного фенотипического и одного этиологического критерия. Эксперты предложили фенотипические критерии для классификации степени тяжести недостаточности питания на умеренную и тяжёлую (табл. 2) [16].

Понимая очевидные недостатки и ограничения скрининговых шкал в решении задач выявления БЭН на ранних стадиях, эксперты разработали модели объективной оценки для прогнозирования риска БЭН у онкологических больных. В качестве анализируемых критериев отбирали различные переменные, а универсальным инструментом служила статистическая модель логистической регрессии. Модель логистической регрессии позволяет анализировать влияние независимых переменных (выбранных с точки зрения их значимости в развитии БЭН) на бинарную переменную (вероятность возникновения БЭН, принимающую значения 0 и 1). Метод вводит линейную комбинацию независимых переменных в логистическую функцию, которая преобразует результат в значение вероятности. Модель логистической регрессии широко используют в медицине для анализа, прогнозирования и классификации факторов риска заболеваний.

В ряде публикаций показаны преимущества предиктивных моделей, основанных на логистической регрессии, перед скрининговыми шкалами [17–21]. Так в ретроспективном клиническом исследовании 2023 г. Т. Dai и соавт. [17] объектом изучения стали клинические данные 344 пациентов, перенёсших лапароскопическую гастрэктомию из-за рака желудка. Используя статистическую матрицу логистической регрессии, авторы разработали модель оценки риска БЭН для пациентов в послеоперационном периоде (в течение трёх месяцев). Электронную базу медицинских данных разделили на обучающую и валидационную выборки в соотношении 7:3. В качестве прогностических переменных авторы отобрали такие критерии, как стадия опухолевого процесса (метастатическое поражение лимфатических узлов), наличие хронической сердечной недостаточности, содержание преальбумина, показатель соотношения нейтрофилов к лимфоцитам, а также старт энтерального питания в течение 48 ч после операции. Результаты исследования показали, что площадь под ROC-кривой (AUC-ROC, Area Under Curve – Receiver Operating Characteristic) составила 0,84 для обучающего набора и 0,854 для валидационной выборки. Индекс конкордантности модели составил 0,84 (95% ДИ, 0,79–0,89), что превышает показатели скрининга БЭН по шкале NRS 2002. Модель также продемонстрировала хорошие адаптивные свойства и приемлемую клиническую применимость: в диапазоне пороговых вероятностей 10–85% прогностическая способность модели оказалась выше, чем у скрининговой шкалы NRS 2002.

Л. Yin и соавт. в 2021 г. в рамках многоцентрового обсервационного когортного исследования выполнили сравнительный анализ данных 1219 пациентов с раком лёгкого. Авторы использовали метод логистической регрессии для построения прогностической модели, включающей шесть переменных: пол, ИМТ, потерю массы тела в течение шести или менее месяцев, величину окружности голени и показатель соотношения силы кистевого сжатия к массе тела. Модель продемонстрировала значение AUC ROC-кривой равной 0,982 (95% ДИ 0,969–0,995) с аналогичными показателями в группе валидации [18, 19]. Примечательно, что рассматриваемые прогностические критерии, используемые в описываемых моделях, неинвазивны и экономичны. Эти данные легко получить с помощью рутинных обследований и базовых антропометрических измерений.

Ј. Tang и соавт. в 2023 г. провели многофакторный анализ электронной базы медицинских данных 506 амбулаторных пациентов с колоректальным раком. Исследователи обобщили демографические данные, истории развития заболевания, симптомы, антропометрические измерения, результаты лабораторных исследований и спектр сопутствующих заболеваний. С помощью модели логистической регрессии исследователи выделили наиболее сильные корреляционные связи между риском БЭН и возрастом, ИМТ, статусом ECOG, наличием отдалённых метастазов, концентрацией альбумина сыворотки крови <3,0 г/дл, синдромом слабости, ассоциированным с онкологическим заболеванием, нарушением моторики кишечника (диареей/констипацией). По мере увеличения суммы баллов с 0 до 9–10, риск БЭН возрастал с 11 до 100%. Модель демонстрировала значение AUC ROC-кривой равное 0,745 (95% ДИ, 0,697–0,793) [20].

В исследовании W. Yu и соавт. 2023 г. авторы применили комбинированный подход, сочетающий радиомику (систему технологий и методов преобразования цифровых медицинских изображений в количественные данные для извлечения дополнительных признаков из изображений, влияющих на принятие решений) и мультипараметрический анализ клинических данных. С помощью радиомических технологий проанализировали компьютерно-томографические (КТ) ~~снимки~~ изображения 120 пациенток с раком шейки матки до начала проведения химиолучевой терапии. Авторы выделили характерные рентгенологические признаки структуры большой поясничной мышцы в КТ-сканах на уровне третьего поясничного позвонка, которые указывают на

возможную БЭН. Для прогнозирования БЭН авторы использовали метод регрессионного анализа LASSO (Least Absolute Shrinkage and Selection Operator, метод наименьших абсолютных усадок и отбора переменных). Для отбора ключевых клинических факторов ими была применена модель бинарной логистической регрессии. Ценность работы заключается в объединении радиомиических характеристик с клиническими факторами риска БЭН. Мультипараметрический анализ показал, что независимыми предикторами БЭН, помимо рентгенологических признаков саркопении, являются пожилой возраст и статус по шкале ECOG >1. В результате исследования авторы разработали предиктивные радиомиические номограммы. Значение AUC ROC-кривых для обучающего и тестового набора данных составил 0,972 и 0,805 соответственно. Анализ кривой принятия решения (DCA, Decision Curve Analysis) также подтвердил клиническую пользу представленной комбинированной модели [21].

X. Zhang и соавт. в 2022 г. в рамках одноцентрового исследования провели ретроспективный анализ медицинских данных 702 онкологических больных, находящихся на стационарном лечении. В качестве прогностических факторов исследователи выбрали ИМТ, возраст, нозологическую форму опухоли, фазовый угол левой руки. Для построения дерева решений применялась модель MO Random Forest («Случайный лес»). Выбранная модель продемонстрировала хорошую производительность с AUC ROC-кривой равной 0,813, чувствительностью 75,9% и специфичностью 73,3%. Фактические и прогнозируемые кривые выживаемости совпали в значительной степени. Однако из-за ограничений ретроспективного дизайна работы авторы не обладали информацией о наличии потенциально значимых факторов, таких как курение, употребление алкоголя, уровень образования и доход пациентов. Учёт этих факторов мог повысить прогностические возможности модели [22].

Целью клинического исследования L. Yin и соавт. в 2021 г. стало упрощение внедрения в клиническую практику шкалы GLIM с помощью технологий MO [15]. Китайские авторы обобщили данные 3998 онкологических пациентов из нескольких центров и применили алгоритм дерева решений для построения модели. Модель включала пять ключевых прогностических факторов: возраст, потерю массы тела за последние 6 мес., ИМТ, окружность икр и скрининговую шкалу NRS 2002. Исследование показало, что каждая из этих пяти переменных имеет разную степень значимости для диагностики нутритивного дефицита, что может дать новое представление о самой оценочной шкале GLIM. Интересно, что возраст имел наименьшую прогностическую ценность. Применяя критерии GLIM, исследователи выявили умеренную недостаточность питания у 588 пациентов (14,7%), а тяжёлую — у 532 пациентов (13,3%). Эффективность предложенной модели оценивали в группе валидации. Модель продемонстрировала высокую дискриминантную способность и AUC ROC-кривой равную 0,964. Анализ подгрупп показал, что модель применима при различных диагнозах. Однако результаты этой работы также требуют осторожной интерпретации ввиду ретроспективности дизайна исследования. Существенным недостатком работы следует считать отсутствие учёта уровня воспаления в качестве прогностического фактора. Однако авторы отмечают, что по сравнению с классическими критериями GLIM, которые учитывают и результаты лабораторных тестов, дерево решений сохраняет функцию оценки степени тяжести БЭН даже при использовании редуцированного набора параметров. При этом все эти параметры являются неинвазивными и доступны для оценки на уровне приёмного покоя [15].

Одну из самых интересных разработок в этом направлении представили китайские коллеги. Они оценили возможность построения модели для раннего выявления БЭН у онкогериатрических пациентов, проходящих лечение в стационаре [23]. Модель разработали на основе анализа электронной медицинской базы данных 450 пациентов в соответствии со следующими критериями отбора: возраст 60 лет и старше; верифицированный диагноз злокачественного новообразования; длительность госпитализации ≥ 1 нед. Для выявления БЭН использовали шкалу PG-SGA. Процесс построения модели в работе R. Duan и соавт. 2024 г. заключался в разделении базы данных на обучающий и валидационный наборы данных в соотношении 4:1, которые использовали для оценки стабильности и производительности прогностической модели. Для валидации модели применяли ROC-анализ, калибровочную кривую и кривую принятия решений. В процессе поиска оптимального алгоритма для предиктивной модели протестировали девять алгоритмов машинного обучения (АМО). Модель XGBoost (extreme gradient boosting, оптимизированный градиентный бустинг), представляющая собой дерево решений, продемонстрировала высокую точность, эффективность и производительность в идентификации БЭН на основе анализа возраста, поведенческой информации, антропометрических данных и лабораторных показателей. По всем характеристикам XGBoost превзошла традиционную

логистическую регрессию. На этом основании R. Duan и соавт. в 2024 г. сделали вывод о целесообразности включения АМО в диагностический контур БЭН [23]. Другим важным выводом данного клинического исследования является высокая частота выявления БЭН — у 46,4% (n=209) пациентов, что демонстрирует чрезвычайную актуальность проблемы нутритивной недостаточности питания у пожилых онкологических пациентов. Также R. Duan и соавт. с помощью алгоритма XGBoost выделили следующие значимые переменные в развитии БЭН: пожилой и старческий возраст, высокий ИМТ, злоупотребление алкоголем, низкие показатели гемоглобина и альбумина, повышенная концентрация С-реактивного белка (для всех переменных $p < 0,05$). При этом авторы признают ограничения исследования, включая невозможность установления причинно-следственных или временных связей в развитии БЭН, а также потенциальную предвзятость пациентов или медицинских работников при оценке субъективных параметров скрининговой шкалы PG-SGA. Также вызывает сомнение, насколько оценка только одного антропометрического показателя как ИМТ может быть адекватным отражением изменения нутритивного статуса. Этот показатель не отражает полную картину, так как не учитывает распространённость сложных форм ожирения, в том числе саркопенического. Кроме того, классическое исследование L. Martin и соавт. продемонстрировало прогностическую значимость не только ИМТ, но и динамики потери массы тела [24]. Ценность результатов снижает отсутствие в исследовательском проекте группы сравнения для валидации полученных результатов.

Авторы другого исследования включили в анализируемые критерии прогностической модели компонентный состав тела на основании измерений биоимпеданса [22]. Они проанализировали ретроспективную выборку из 702 взрослых онкологических больных, находящихся на стационарном лечении. Выборка включала демографические данные, клинические параметры и результаты оценки биофазового угла. В качестве диагностического стандарта для оценки нутритивного статуса использовали шкалу субъективной глобальной оценки PG-SGA. Недостаточность питания определяли как PG-SGA ≥ 4 баллов. Для выбора значимых переменных и разработки прогностических моделей применили несколько методов, включая дерево решений. Результаты по шкале PG-SGA использовали в бинарном виде (PG-SGA < 4 или PG-SGA ≥ 4). Согласно критериям PG-SGA, у 490 (69,8%) пациентов отмечали БЭН. Анализ показал, что на наличие БЭН влияют возраст, онкологический диагноз и ИМТ, а также что БЭН коррелирует со значением фазового угла при биоимпедансном измерении. Последнее измерение включили в окончательную прогностическую модель. Модель показала хорошие результаты: чувствительность составила 75,9%, специфичность — 73,3%, AUC ROC-кривой — 0,813.

Несмотря на очевидную практическую значимость, универсальным ограничением приведённых выше исследований является их ретроспективный характер, небольшой объём выборки и определённый субъективизм в выборе прогностических критериев, которые потенциально коррелируют с вероятностью развития БЭН. Безусловно, для получения более достоверных результатов необходимы проспективные крупномасштабные исследования, охватывающие различные когорты пациентов и обязательно включающие внешнюю валидацию моделей.

В условиях активного внедрения передовых цифровых технологий, методики МО стали перспективным направлением исследования. Это связано с их способностью автоматически выявлять сложные взаимосвязи между признаками, облегчать прогностический анализ и эффективно использовать многомерные переменные из электронной базы медицинских данных [25]. АМО обладают потенциальными преимуществами не только в производительности, но также в точности и объективности по сравнению с традиционными статистическими методами. Таким образом, их можно успешно использовать, в том числе для выявления БЭН. В целом, АМО дают уникальную возможность перевести анализ больших объёмов медицинских данных на качественно новый уровень, делая его проще и результативнее. Эти алгоритмы позволяют выявлять скрытые закономерности, строить точные прогнозы и эффективно использовать всю полноту информации из электронных медицинских записей.

ПРОБЛЕМЫ, СТОЯЩИЕ ПЕРЕД ВРАЧЕБНЫМ СООБЩЕСТВОМ

Для эффективного взаимодействия связки «искусственный интеллект – врач» необходимо чётко осознавать, что, несмотря на обоснованный консерватизм медицинского сообщества, будущее медицины за синергией человеческого и искусственного интеллектов. В то же время модели МО являются лишь инструментами, подобными скальпелю или рентгеновскому лучу, которые помогают врачам, но не способны их заменить.

Эксперты в области цифровых технологий признают, что современным моделям МО не хватает таких важных характеристик, как полнота, прозрачность и понятность. На сегодняшний день любая модель МО представляет собой своеобразный «чёрный ящик» для принятия решений. Это значительно затрудняет её понимание и восприятие врачебным сообществом в качестве надёжного инструмента. Безусловно, прозрачность модели повысила бы доверие со стороны врачей и пациентов, что важно для её внедрения в практику. Большинству моделей МО не хватает настроек и возможностей для интерпретации результатов. При этом в такой ответственной сфере, как медицина, интерпретация имеет решающее значение, поскольку напрямую связана с безопасностью пациентов. В связи с этим важно, чтобы ИИ обучался на больших объёмах качественных и актуальных данных.

В процессе совершенствования технологий ИИ предстоит ответить на следующие вопросы:

- какой АМО является оптимальным для выявления БЭН?
- какие факторы риска БЭН, которые анализирует ИИ, следует считать обязательными?

Безусловным условием является интеграция ИИ в действующие медицинские информационные системы, чтобы врачи могли максимально легко применять его на практике.

Несомненно, для валидации прогностических моделей требуются многоцентровые рандомизированные проспективные клинические исследования на больших когортах пациентов. Кроме того, необходимо решить целый ряд этических и правовых вопросов, связанных с внедрением ИИ в практическую медицину, таких как конфиденциальность данных и ответственность за принятые решения.

ЗАКЛЮЧЕНИЕ

Технологии искусственного интеллекта, в том числе модели машинного обучения, продемонстрировали высокий потенциал в решении сложных задач по выявлению белково-энергетической недостаточности среди больших когорт онкологических больных. В качестве основы для разработки таких алгоритмов используют общепринятые и валидированные для онкологии скрининговые шкалы: NRS 2002, PG-SGA, GLIM. Результаты клинических исследований демонстрируют целесообразность и необходимость внедрения моделей машинного обучения для ранней диагностики нутритивной недостаточности. Однако для масштабирования результатов требуется тесное сотрудничество профессионального медицинского сообщества, программистов, национальных регуляторов и юристов.

ДОПОЛНИТЕЛЬНАЯ ИНФОРМАЦИЯ

Вклад авторов. М.Ю. Кукош — разработка концепции, обзор литературы, сбор и анализ литературных источников, написание текста и редактирование статьи; О.А. Обухова — обзор литературы, сбор и анализ литературных источников, редактирование текста статьи; Все авторы подтверждают соответствие своего авторства международным критериям ICMJE (все авторы внесли существенный вклад в разработку концепции, проведение исследования и подготовку статьи, прочли и одобрили финальную версию перед публикацией).

Источник финансирования. Авторы заявляют об отсутствии внешнего финансирования при проведении исследования и подготовке публикации.

Раскрытие интересов. Авторы заявляют об отсутствии отношений, деятельности и интересов за последние три года, связанных с третьими лицами (коммерческими и некоммерческими), интересы которых могут быть затронуты содержанием статьи.

Оригинальность. При создании настоящей работы авторы не использовали ранее опубликованные сведения (текст, иллюстрации, данные).

Доступ к данным. Все данные, полученные в настоящем исследовании, доступны в статье и в приложении к ней.

Генеративный искусственный интеллект. Не применимо.

Рассмотрение и рецензирование. Настоящая работа подана в журнал в инициативном порядке и рассмотрена по обычной процедуре. В рецензировании участвовали два внешних рецензента, член редакционной коллегии и научный редактор издания

ADDITIONAL INFORMATION

Author contribution. M.Yu. Kukosh — concept development, literature review, collection and analysis of literary sources, writing the text and editing the article; O.A. Obukhova — literature review, collection

and analysis of literary sources, editing the text of the article; All authors confirm that their authorship complies with the international ICMJE criteria (all authors made a significant contribution to the concept development, research, and preparation of the article, read and approved the final version before publication).

Funding sources. This study was not supported by any external sources of funding.

Competing interests. The author declares no relationships, activities, or interests over the past three years involving third parties (commercial or non-commercial) that could be affected by the article's content.

Statement of originality. In creating this work, the author did not use any previously published materials (text, illustrations, data).

Data availability statement. Not applicable.

Generative AI. No generative AI technologies were used in the creation of this article.

Provenance and peer-review. This manuscript was submitted voluntarily and underwent standard peer review, including evaluation by two external reviewers, an editorial board member, and the journal's scientific editor.

СПИСОК ЛИТЕРАТУРЫ | REFERENCES

1. Stafford IS, Kellermann M, Mossotto E, et al. A systematic review of the application so far artificial intelligence and machine learning in autoimmune diseases. *NPJ Digit. Med.* 2020;3:30. doi: 10.1038/s41746-020-0229-3 EDN: AYJNYL
2. Dinh A, Miertschin S, Young A, Mohanty SD. A data-driven approach to predicting diabetes and cardiovascular disease with machine learning. *BMC Med. Inform. Decis. Mak.* 2019;19:211. doi: 10.1186/s12911-019-0918-5 EDN: ZBLPDC
3. Cho YR, Kang M. Interpretable machine learning in bioinformatics. *Methods.* 2020;179:1–2. doi: 10.1016/j.ymeth.2020.05.024 EDN: GPVDWK
4. Collin C, Wade DT, Davies S, Horne V. The Barthel ADL Index: are liability study. *Int. Disabil. Stud.* 1988;10:61–63. doi: 10.3109/09638288809164103
5. Mor V, Laliberte L, Morris JN, Wiemann M. The karnofsky performance status scale. An examination of its reliability and validity in a research setting. *Cancer.* 1984;53(9):2002-7. doi: 10.1002/1097-0142(19840501)53:9<2002::aid-cnrc2820530933>3.0.co;2-w
6. Giantonio BJ, Forastiere AA, Comis RL; Eastern Cooperative Oncology Group. The role of the Eastern Cooperative Oncology Group in establishing standards of cancer care: over 50 years of progress through clinical research. *Semin. Oncol.* 2008;35(5):494-506. doi: 10.1053/j.seminoncol.2008.07.004
7. Sytov AV, Obukhova OA, Matveeva SO, et al. Oncologists' awareness of the ERAS protocols and RUSSCO guidelines key provisions on nutritional support in patients with cancer. *Clinical nutrition and metabolism.* 2024;5(3):114–121. doi: 10.17816/clinutr677829 EDN: OTCZVA
8. Singer P, Blaser AR, Berger MM, et al. ESPEN practical and partially revised guideline: Clinical nutrition in the intensive care unit. *Clin. Nutr.* 2023;42(9):1671-1689. doi: 10.1016/j.clnu.2023.07.011 EDN: TQSVZO
9. Singer P. How to prescribe parenteral nutrition the safest way: case by case or using machine learning? *J. Intensive Med.* 2022;2(2):67-68. doi: 10.1016/j.jointm.2022.03.002 EDN: HSSIYU
10. Berger MM, Reintam Blaser A, Raphaeli O, Singer P. Early feeding in critical care - where are we now? *Crit. Care Clin.* 2025;41(2):213-231. doi: 10.1016/j.ccc.2024.09.002 EDN: GYWWHF
11. Kondrup J, Allison SP, Elia M, et al. ESPEN guidelines for nutrition screening 2002. *Clin. Nutr.* 2003;22(4):415–421. doi: 10.1016/S0261-5614(03)00098-0
12. Sytov AV, Zuzov SA, Kukosh MYu, et al. Nutritional support. RUSSCO practical recommendations, part 2. *Malignant tumors* 2024;14(3s2):163–173. doi: [10.18027/2224-5057-2024-14-3s2-2-08](https://doi.org/10.18027/2224-5057-2024-14-3s2-2-08)
13. Balstad TR, Bye A, Jenssen CR, et al. Patient interpretation of the patient-generated subjective global assessment (PG-SGA) short form. *Patient Prefer. Adherence.* 2019;13:1391–1400. doi: 10.2147/PPA.S204188
14. Contreras-Bolivar V, Sanchez-Torralvo FJ, Ruiz-Vico M, et al. GLIM criteria using hand grip strength adequately predict six-month mortality in cancer inpatients. *Nutrients.* 2019;11(9):2043. doi: 10.3390/nu11092043

15. Yin L, Lin X, Liu J, et al. Classification tree-based machine learning to visualize and validate a decision tool for identifying malnutrition in cancer patients. *JPEN*. 2021;45:1736–48. doi: 10.1002/jpen.2070 EDN: WPQVBH
16. Cederholm T, Jensen GL, Correia MITD, et al. GLIM criteria for the diagnosis of malnutrition: A consensus report from the global clinical nutrition community. *Clin. Nutr.* 2018;38(1):1-9. doi: 10.1016/j.clnu.2018.08.002
17. Dai T, Wu D, Tang J, et al. Construction and validation of a predictive model for the risk of three-month-postoperative malnutrition in patients with gastric cancer: a retrospective case-control study. *J. Gastrointest. Oncol.* 2023;4:128–45. doi: 10.21037/jgo-22-1307 EDN: LEUNDC
18. Yin L, Lin X, Li N, et al. Evaluation of the global leadership initiative on malnutrition criteria using different muscle mass indices for diagnosing malnutrition and predicting survival in lung cancer patients. *JPEN*. 2021;45(3):607-617. doi: 10.1002/jpen.1873 EDN: RMSZOB
19. Yin L, Liu J, Lin X, et al. Development and validation of a rapid-decision pathway to diagnose malnutrition in patients with lung cancer. *Nutrition*. 2021;84:111102. doi: 10.1016/j.nut.2020.111102 EDN: IJIRFV
20. Tang J, Wong G, Naffouje S, et al. A novel nomogram for early identification and intervention in colorectal cancer patients at risk for malnutrition. *Am. Surg.* 2023;89:1485–96. doi: 10.1177/00031348211058620 EDN: HSE AHL
21. Yu W, Xu H, Chen F, et al. Development and validation of a radiomics-based nomogram for the prediction of postoperative malnutrition in stage IB1-IIA2 cervical carcinoma. *Front. Nutr.* 2023;10:1113588. doi: 10.3389/fnut.2023.1113588 EDN: IWPPUI
22. Zhang X, Zhao W, Du Y, et al. A simple assessment model based on phase angle for malnutrition and prognosis in hospitalized cancer patients. *Clin. Nutr.* 2022;41:1320–7. doi: 10.1016/j.clnu.2022.04.018 EDN: MHFQCS
23. Duan R, Lic Q, Yuand Q, et al. Predictive model for assessing malnutrition in elderly hospitalized cancer patients: a machine learning approach. *Geriatr. Nurs.* 2024;58:388-398. doi: 10.1016/j.gerinurse.2024.06.012 EDN: DMQLPD
24. Martin L, Senesse P, Gioulbasanis I, et al. Diagnostic criteria for the classification of cancer-associated weight loss. *J. Clin. Oncol.* 2015;33(1):90-9. doi: 10.1200/JCO.2014.56.1894
25. Manning AM, Casper KA, Peter KS, et al. Can predictive modeling identify head and neck oncology patients at risk for readmission? *Otolaryngology (Rochester, Minn.)*. 2018;159:669–74. doi: 10.1177/0194599818775938

ИНФОРМАЦИЯ ОБ АВТОРАХ

*Автор, ответственный за переписку:	
* Обухова Ольга Аркадьевна, канд. мед. наук; адрес: Россия, 115522, Москва, Каширское ш., д. 24; ORCID: 0000-0003-0197-7721; eLibrary SPIN: 6876-7701; e-mail: obukhova0404@yandex.ru	* Olga A. Obukhova, MD, Cand. Sci. (Medicine); address: 24 Kashirskoe hwy, Moscow, Russia, 115522; ORCID: 0000-0003-0197-7721; eLibrary SPIN: 6876-7701; e-mail: obukhova0404@yandex.ru
Мария Юрьевна Кукош, канд. мед. наук; ORCID: 0000-0001-6481-1724; eLibrary SPIN: 9093-8296 e-mail: manja70@inbox.ru	Mariya Yu. Kukosh, MD, Cand. Sci. (Medicine); ORCID: 0000-0001-6481-1724; eLibrary SPIN: 9093-8296; e-mail: manja70@inbox.ru

ТАБЛИЦЫ

Таблица 1. Скрининговая шкала GLIM

Table 1. GLIM screening scale

Термин	Определение и критерии	
Нутритивная недостаточность	Обязательный скрининг нутритивной недостаточности	Определение риска нутритивной недостаточности по валидированным скрининговым шкалам, например, NRS 2002, MUST, SNAQ, MST или др.
	Фенотипические критерии	Потеря или низкая масса тела, что определяется по наличию хотя бы одного из следующих критериев: A1: потеря массы тела >5% за 6 мес. A2: ИМТ ниже 20 кг/м ² A3: низкая мышечная масса
	Этиологические критерии	Снижение потребления пищи (B1) и / или повышенный катаболизм (B2) B1 (голодный тип): снижение потребления пищи B1a: потребление пищи < 50% в течение >1 недели B1b: любое снижение потребления пищи в течение > 2 недель B1c: хроническая мальабсорбция B2 (кахектический тип): усиление острого или хронического системного воспаления

Примечание: Определяется наличием 3-х критериев: положительный скрининговый тест нутритивной недостаточности, один фенотипический критерий, один этиологический критерий.

Таблица 2. Градация выраженности белково-энергетической недостаточности по шкале GLIM

Table 2. Gradation of the severity of protein-energy malnutrition according to the GLIM scale

Степень выраженности БЭН	Потеря массы тела, %	ИМТ, кг/м ²	Потеря мышечной массы
Умеренная	5-10% за 6 мес.	<20, если возраст <70 лет	Слабая и умеренная
	10-20% за больший промежуток времени	<22, если возраст ≥70 лет	
Тяжелая	>10% за 6 мес.	<18,5, если возраст <70 лет	Тяжелая
	>20% за больший промежуток времени	<20, если возраст ≥70 лет	

РИСУНКИ



Рис. 1. Протокол назначения клинического питания.

Fig. 1. Protocol for the appointment of clinical nutrition.