

ПРИМЕНЕНИЕ МАШИННОГО ОБУЧЕНИЯ ДЛЯ ПРОГНОЗИРОВАНИЯ РЕЗУЛЬТАТОВ ВЕЛОЭРГОМЕТРИЧЕСКОЙ ПРОБЫ: ПРОСПЕКТИВНОЕ КОГОРТНОЕ ИССЛЕДОВАНИЕ

DOI: 10.17691/stm2026.18.2.06

УДК 612.76:004.85

Поступила 09.09.2025 г.

© **Е.В. Березина**, д.т.н., зав. кафедрой физики, химии и математики¹;
К.А. Блинова, к.м.н., доцент кафедры онкологии и лучевой терапии¹;
О.А. Дмитриева, к.х.н., научный сотрудник²;
И.Е. Мишина, д.м.н., профессор кафедры последипломного медицинского образования;
первый зам. директора Медицинского института³

¹Ивановский государственный медицинский университет, Шереметевский проспект, 8,
Иваново, 153012;

²Институт химии растворов им. Г.А. Крестова Российской академии наук, ул. Академическая, 1,
Иваново, 153045;

³Санкт-Петербургский государственный университет, Университетская набережная, 7/9,
Санкт-Петербург, 199034

Цель исследования — разработка оптимального метода прогнозирования результатов велоэргометрической (ВЭМ) пробы на основе параметров, регистрируемых во время теста с шестиминутной ходьбой (ТШХ), с использованием методов машинного обучения.

Материалы и методы. В исследовании участвовали 56 пациентов, перенесших острый инфаркт миокарда и проходивших второй этап кардиореабилитации. Выполнено комплексное обследование, включающее сбор анамнеза, физикальное обследование, антропометрическую оценку, а также симптом-лимитированную ВЭМ-пробу и ТШХ. Во время ТШХ регистрировали пройденную дистанцию, частоту сердечных сокращений, артериальное давление, сатурацию кислорода, воспринимаемое напряжение по шкале Борга, количество пройденных шагов и электрокардиографические данные. Для построения моделей машинного обучения использовали алгоритмы случайного леса, градиентного бустинга, метода k-ближайших соседей и множественной линейной регрессии. Производительность моделей оценивали на основе коэффициента детерминации, средней абсолютной ошибки, среднеквадратичной ошибки и корня из среднеквадратичной ошибки. Для интерпретации результатов применяли SHAP-анализ.

Результаты. Модель градиентного бустинга обеспечивает наилучшее качество прогноза с высоким коэффициентом детерминации (R^2 около 0,99) и низкими значениями ошибок для обеих целевых метрик: пройденной дистанции в ТШХ и метаболического эквивалента, достигнутого при ВЭМ-пробе. Анализ значимости признаков выявил, что частота сердечных сокращений, возраст и индекс массы тела оказывают наибольшее влияние на прогнозирование дистанции ТШХ, в то время как для прогнозирования метаболического эквивалента наиболее значимыми являются пройденное расстояние, количество пройденных шагов и индекс массы тела.

Заключение. Разработанная модель машинного обучения на основе градиентного бустинга продемонстрировала высокую эффективность в прогнозировании результатов ВЭМ-пробы на основе данных ТШХ. Предложенный метод может служить ценным вспомогательным инструментом для планирования программ кардиореабилитации, особенно в случаях, когда проведение ВЭМ-пробы затруднено или невозможно. Использование SHAP-анализа способствовало пониманию вклада каждого признака в прогноз, повышая доверие к результатам модели.

Ключевые слова: машинное обучение; велоэргометрическая проба; тест с шестиминутной ходьбой; кардиореабилитация; прогнозирование; градиентный бустинг.

Как цитировать: Berezina E.V., Blinova K.A., Dmitrieva O.A., Mishina I.E. Machine learning application to predict bicycle ergometer test results: a prospective cohort study. *Sovremennye tehnologii v medicine* 2026; 18(2): 63, <https://doi.org/10.17691/stm2026.18.2.06>
Это статья с открытым доступом, распространяемая по лицензии CC BY 4.0 (<https://creativecommons.org/licenses/by/4.0/>).

Для контактов: Блинова Ксения Александровна, e-mail: k.a.blinova@mail.ru

Machine Learning Application to Predict Bicycle Ergometer Test Results: a Prospective Cohort Study

E.V. Berezina, DSc, Head of the Department of Physics, Chemistry, and Mathematics¹;
K.A. Blinova, MD, PhD, Associate Professor, Department of Oncology and Radiation Therapy¹;
O.A. Dmitrieva, PhD, Researcher²;
I.E. Mishina, MD, DSc, Professor, Department of Postgraduate Medical Education;
First Deputy Director of Medical Institute³

¹Ivanovo State Medical University, 8 Sheremetevsky Prospect, Ivanovo, 153012, Russia;

²G.A. Krestov Institute of Solution Chemistry of the Russian Academy of Sciences,
1 Akademicheskaya St., Ivanovo, 153045, Russia;

³Saint Petersburg State University, 7/9 Universitetskaya naberezhnaya, Saint Petersburg, 199034, Russia

The aim of the study was to develop an optimal technique to predict the results of a bicycle ergometry test (BET) based on the parameters recorded during a six-minute walk test (6MWT) using machine learning methods.

Materials and Methods. The study involved 56 patients who had experienced acute myocardial infarction and were undergoing the second stage of cardiac rehabilitation. The patients underwent a complete examination, including history taking, physical examination, anthropometric assessment, as well as a symptom-limited BET and 6MWT. During the 6MWT, we recorded the following: the distance covered, the heart rate, the blood pressure, the oxygen saturation, Borg rating of perceived exertion, the number of steps taken, and the electrocardiographic data. The algorithms for random forest, gradient boosting, k-nearest neighbors, and multiple linear regression were used to construct the machine learning models. The performance of the models was evaluated based on a determination coefficient, a mean absolute error, a mean square error, and a root mean square error. SHAP analysis was applied to interpret the findings.

Results. The gradient boosting model provided the best prediction quality with a high determination coefficient (R^2 being around 0.99) and low error values for both target metrics: the distance walked in the 6MWT and the metabolic equivalent achieved during the BET. The significance analysis of features revealed the heart rate, age, and the body mass index to have the greatest impact on predicting the 6MWT distance, while for predicting the metabolic equivalent, the distance covered, the number of steps, and the body mass index were the most significant.

Conclusion. The developed gradient boosting-based machine learning model demonstrated its high efficiency in predicting the results of the 6MWT-based BET. The suggested method can serve as a valuable auxiliary tool to plan cardiac rehabilitation programs, particularly in cases when BET is difficult or impossible to perform. The use of SHAP analysis helped to understand the contribution of each feature to the prediction, increasing the confidence in the model results.

Key words: machine learning; bicycle ergometry test; six-minute walk test; cardiac rehabilitation; prediction; gradient boosting.

Введение

Сердечно-сосудистые заболевания (ССЗ) представляют собой серьезную проблему для мирового здравоохранения, являясь ведущей причиной заболеваемости и смертности [1]. По данным Всемирной организации здравоохранения, ССЗ ответственны за 19 млн смертей в год, что соответствует примерно 32% от общей глобальной летальности [2]. Важным элементом комплексного ведения пациентов с ССЗ является кардиореабилитация, обеспечивающая целостный подход к восстановлению и вторичной профилактике. Результаты систематических обзоров свидетельствуют о положительном влиянии кардиореабилитации на выживаемость пациентов, перенесших острый коронарный синдром, по сравнению с группами контроля, не участвовавшими в программах кардиореабилитации [3–5]. Отмечено снижение смертности от ССЗ на 26% и уменьшение частоты повторных госпитализаций на 18% [6]. Конечной целью кар-

диореабилитации является восстановление пациента и обеспечение его полноценной реинтеграции в привычную среду без функциональных ограничений, что в совокупности способствует улучшению клинического статуса, качества жизни и прогноза выживаемости [7].

Для оценки переносимости физической нагрузки при назначении тренировок в кардиореабилитации используются различные нагрузочные пробы. При помощи велоэргометра (велоэргометрическая проба — ВЭМ-проба) определяется метаболический эквивалент (metabolic equivalent of task — MET) выполняемой нагрузки. Однако данный метод характеризуется относительно высокой стоимостью и значительными временными затратами [8]. Несмотря на возможность периодического использования ВЭМ-пробы в рамках проведения программы кардиореабилитации, для рутинного мониторинга физической работоспособности пациентов чаще применяется тест с шестиминутной ходьбой (ТШХ). Данный тест представляет собой экономичный, относительно

быстрый и безопасный метод оценки функциональной переносимости физической нагрузки у пациентов с патологией сердечно-сосудистой системы. Его широкое применение обусловлено возможностью мониторинга течения различных ССЗ, а также оценки эффективности терапевтических и реабилитационных вмешательств [9, 10]. Следует отметить, что ВЭМ-проба и ТШХ принципиально различаются. ВЭМ-проба предполагает достижение максимальной физической нагрузки в течение 8–12 мин посредством использования протокола с постепенно возрастающей интенсивностью [11], в то время как ТШХ является пробой с постоянной интенсивностью нагрузки и традиционно классифицируется как субмаксимальная, что делает ее более безопасной. В частности, выполнение максимального теста, такого как ВЭМ-проба, сопряжено с более высоким риском для пациентов с тяжелым клиническим состоянием по сравнению с субмаксимальными нагрузками (ТШХ) [12]. Данный факт подтверждается различиями в требованиях к обеспечению безопасности при проведении этих двух тестов, включая необходимость наличия квалифицированного персонала, дефибриллятора, электрокардиографического мониторинга и средств для оказания неотложной помощи. Таким образом, в клинической практике часто возникает проблема определения оптимальной интенсивности физических нагрузок при проведении тренировок в рамках кардиореабилитации, особенно в тех случаях, когда выполнение ВЭМ-пробы невозможно по различным причинам.

В последние годы в медицинском сообществе растет интерес к достижениям в области искусственного интеллекта (ИИ), что, в частности, стимулировало внедрение систем мониторинга в реабилитационную практику [13]. Одной из ключевых сфер применения ИИ является обработка и категоризация изображений, что уже реализовано во многих медицинских направлениях, включая радиологию, онкологию, дерматологию и кардиологию [14–17]. ИИ все чаще используется в роботизированной хирургии, геномике, прогнозировании клинических исходов и в процессах принятия решений. Результаты исследований нередко демонстрируют, что ИИ может достигать уровня компетентности клиницистов или даже превосходить его.

Методы машинного обучения применяются для моделирования комплексных взаимодействий между множеством переменных [14–17]. В частности, оценка эффективности кардиореабилитации требует анализа клинических, психологических и антропометрических параметров, а также показателей, связанных с факторами риска и кардиопротективными привычками. Технологии ИИ способны обеспечивать интеграцию данных, получаемых из различных источников, включая сенсоры для регистрации физиологических параметров, таких как артериальное давление, частота сердечных сокращений (ЧСС), данные электрокардиографии при физической нагрузке, сатурация кислорода (SpO_2) в крови и другие.

Таким образом, появляется потенциальная возможность прогнозирования данных ВЭМ-пробы на основе различных параметров, получаемых с дистанционных биосенсоров во время проведения ТШХ.

Несмотря на растущий интерес к ИИ в медицине, в области реабилитации проведено лишь несколько исследований. Почти двадцать лет назад М. Zhu с соавт. [18] в сравнительном исследовании с участием более 20 000 пациентов, получающих уход на дому, показали, что даже простой алгоритм k-ближайших соседей может точнее предсказать реабилитационный потенциал, чем стандартные протоколы клинической оценки. В дальнейших исследованиях М. Zhu с соавт. [19] установили, что метод опорных векторов и случайные леса значительно превосходят традиционные методы анализа данных, применяемые в области реабилитации.

W.Y. Lin с соавт. [20] использовали машинное обучение для прогнозирования результатов реабилитации после инсульта. Анализ данных примерно 300 пациентов с помощью логистической регрессии, метода опорных векторов и случайного леса показал, что регрессионные алгоритмы позволяют оценить значение индекса Бартела (Barthel index) со средней абсолютной ошибкой около 10, а классификаторы обеспечивают точность более 70% при разделении пациентов на три категории по уровню активности.

Цель исследования — разработка оптимального метода прогнозирования результатов ВЭМ-пробы на основе параметров, регистрируемых во время ТШХ, с использованием методов машинного обучения. Данное исследование направлено на создание эффективного вспомогательного инструмента для планирования программ кардиореабилитации.

Материалы и методы

Проведено проспективное когортное исследование, в котором были проанализированы данные 56 пациентов, перенесших острый инфаркт миокарда: 45 мужчин (79,4%) и 11 женщин (20,6%). Исследование выполнено в Кардиологическом диспансере (Иваново), где в условиях круглосуточного стационара пациенты проходили второй этап кардиореабилитации.

Все пациенты прошли комплексное обследование, включающее сбор жалоб и анамнестических данных, физикальное обследование, а также антропометрическую оценку (рост, масса тела, индекс массы тела — ИМТ). Всем пациентам в течение 24 ч до начала программ физической реабилитации были проведены симптом-лимитированная ВЭМ-проба и ТШХ. Основанием для прекращения ВЭМ-пробы служил отказ пациента от дальнейшего выполнения теста по причине субъективной непереносимости физической нагрузки (выраженная усталость, болевой синдром в нижних конечностях, одышка и т.п.). Данное состояние интерпретировалось как достижение предела переносимости физической нагрузки. ТШХ проводили под ЭКГ-контролем с исполь-

зованием телемедицинской системы «Аккордикс» (ООО «Нейрософт», Иваново). Система «Аккордикс» предназначена для дистанционного мониторинга и регистрации физиологических параметров, в частности ЭКГ в состоянии покоя и при физической нагрузке. Функциональные возможности системы включают автоматизированный анализ регистрируемых данных в режиме реального времени, в том числе при проведении ТШХ. На начальном этапе оценивали следующие показатели: дистанцию, пройденную пациентами в ходе ТШХ; достигнутую мощность нагрузки при выполнении ВЭМ-пробы (в МЕТ); наличие динамических изменений на ЭКГ в процессе выполнения обеих проб. До прохождения нагрузочных проб измеряли ЧСС, артериальное давление и SpO₂. При проведении ТШХ кроме пройденного расстояния оценивали воспринимаемое напряжение по шкале Борга (шкала 6–20 баллов) и количество пройденных шагов.

Для достижения поставленных целей были построены несколько моделей машинного обучения: регрес-

сия случайного леса (random forest regression, RFR), градиентный бустинг (gradient boosting), k-ближайших соседей (k-nearest neighbors, kNN) и множественная линейная регрессия (multiple linear regression, MLR). Разработку моделей машинного обучения и визуальный анализ результатов проводили на языке программирования Python с использованием сервиса Google Colab.

Как известно, наличие сильно коррелирующих показателей приводит к снижению производительности модели из-за высокой дисперсии и меньшей интерпретируемости [21]. По этой причине было задано пороговое значение коэффициента корреляции для рассматриваемых признаков, равное 0,7. При превышении этого порога один из коррелирующих признаков исключался. В результате построения матрицы корреляции признаков исходной выборки были найдены два показателя, которые исключили из дальнейшего анализа: функциональный класс хронической сердечной недостаточности и функциональный класс ишемической болезни сердца (рис. 1).




Рис. 1. Матрица корреляции исследуемых показателей пациентов

Возраст — средний возраст пациентов, лет; ИМТ — индекс массы тела; ЧСС — частота сердечных сокращений до прохождения теста с шестиминутной ходьбой (ТШХ), ударов в минуту; САД — систолическое артериальное давление до прохождения ТШХ, мм рт. ст.; ДАД — диастолическое артериальное давление до прохождения ТШХ, мм рт. ст.; SpO₂ — сатурация кислорода, %; шкала Борга — воспринимаемое напряжение по шкале Борга, баллы; расстояние — пройденное расстояние, м; ФК ХСН — функциональный класс хронической сердечной недостаточности; ФК ИБС — функциональный класс ишемической болезни сердца; количество шагов — количество пройденных шагов

Результаты

Две полученные модели (регрессия случайного леса и градиентный бустинг) характеризуются достаточно высоким коэффициентом детерминации. В модели k-ближайших соседей и множественной линейной регрессии значения данного коэффициента меньше 0,5 в случае предсказания величины ТШХ. Это означает, что на долю вариационных факторных признаков приходится меньшая часть дисперсии по сравнению с остальными факторами, не учтенными в модели и влияющими на изменение результа-

тивного показателя. Построенные при таких условиях регрессионные модели имеют низкое практическое значение. Модель градиентного бустинга показала лучшие результаты по всем показателям, демонстрируя самые высокие значения корректировки и самую низкую частоту ошибок (см. таблицу).

Для более подробного разбора факторов, влияющих на прогнозируемые величины в модели градиентного бустинга, была построена столбчатая диаграмма признаков, отсортированных по среднему SHAP-значению (рис. 2, а). Можно видеть, что абсолютная важность некоторых признаков довольно

Параметры предсказуемых моделей

Модели	Тест с шестиминутной ходьбой				Метаболический эквивалент			
	R ²	MAE	MSE	RMSE	R ²	MAE	MSE	RMSE
Регрессия случайного леса	0,88	3,43	17,22	4,15	0,90	0,28	0,12	0,35
Градиентный бустинг	0,99	0,76	0,99	0,99	0,99	0,06	0,01	0,07
Метод k-ближайших соседей	0,46	6,93	75,42	8,68	0,67	0,47	0,39	0,62
Множественная линейная регрессия	0,30	7,81	98,92	9,95	0,52	0,62	0,57	0,75

Примечание: R² — коэффициент детерминации; MAE — средняя абсолютная ошибка; MSE — среднеквадратичная ошибка; RMSE — корень из среднеквадратичной ошибки.

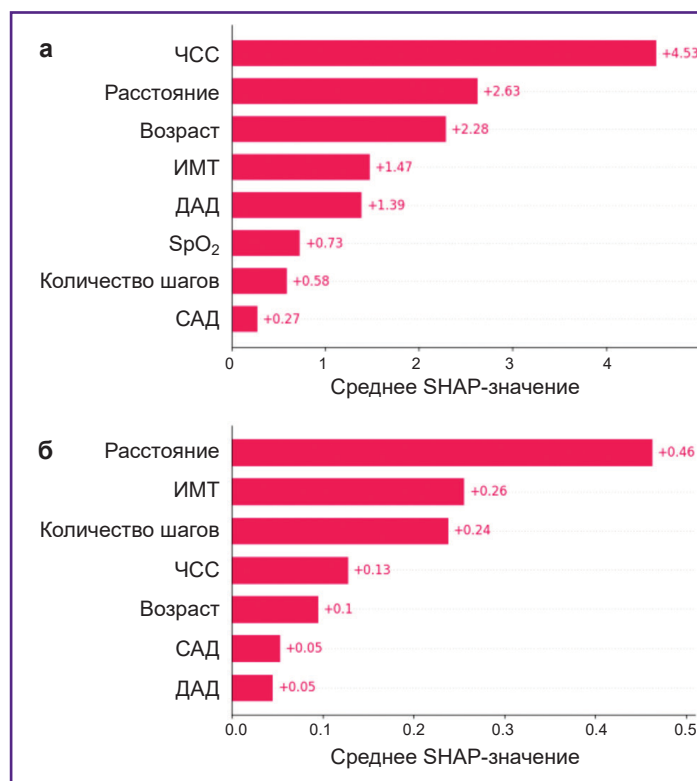


Рис. 2. Среднее абсолютное SHAP-значение признаков в модели градиентного бустинга для теста с шестиминутной ходьбой (ТШХ) (а) и метаболического эквивалента (б)

ЧСС — частота сердечных сокращений до ТШХ, ударов в минуту; расстояние — пройденное расстояние, м; возраст — средний возраст пациентов, лет; ИМТ — индекс массы тела; ДАД — диастолическое артериальное давление до прохождения ТШХ, мм рт. ст.; SpO₂ — сатурация кислорода, %; количество шагов — количество пройденных шагов; САД — систолическое артериальное давление до прохождения ТШХ, мм рт. ст.

велика. Так, для прогнозирования величины ТШХ наиболее значимым является показатель ЧСС с SHAP-значением 4,53; меньший вклад в прогнозирование оказывают пройденное расстояние (SHAP-значение 2,63) и возраст пациента (SHAP-значение 2,28). ИМТ имеет SHAP-значение 1,47. В случае прогнозирования MET (рис. 2, б) наибольший вклад вносит пройденное расстояние с SHAP-значением 0,46; далее по нисходящей — ИМТ (SHAP-значение 0,26) и количество пройденных шагов (SHAP-значение 0,24). ЧСС, возраст, систолическое и диастолическое артериальное давление имеют наименьшее влияние на прогнозирование величины MET.

Обсуждение

В отличие от работ Н. De Cannière с соавт. [22], F. Desai с соавт. [23] и N. Alshurafa с соавт. [24], которые использовали метод опорных векторов, случайные леса, деревья решений или нейронные сети для мониторинга пациентов, мы применили градиентный бустинг, что представляет собой относительно новый подход в данной области. Н. De Cannière с соавт. [22] в модели опорных векторов достигли средней абсолютной ошибки $42,8 \pm 36,8$ при прогнозировании функциональной работоспособности, оцениваемой по дистанции ТШХ, в то время как указанная модель градиентного бустинга продемонстрировала значительно более низкие значения ошибок для обеих целевых метрик (ТШХ и MET).

SHAP-анализ, использованный для интерпретации результатов модели градиентного бустинга, позволил определить наиболее значимые переменные в прогнозировании исходов ВЭМ-пробы. Этот анализ также выявил различия в значимости признаков для прогнозирования дистанции ТШХ и MET.

Для прогнозирования дистанции ТШХ наиболее важными оказались ЧСС до начала теста, возраст пациента и ИМТ. Более высокий ИМТ часто ассоциирован с ухудшением физической формы, снижением аэробной способности и повышенной нагрузкой на опорно-двигательный аппарат, что может ограничивать пройденное расстояние [25]. Исходная ЧСС отражает вегетативный тонус и функциональное состояние сердечно-сосудистой системы, что влияет на физическую работоспособность [26]. С возрастом происходит снижение функциональных резервов организма, что также негативно сказывается на пройденном расстоянии [27].

В свою очередь для прогнозирования параметра MET наиболее важными оказались количество пройденных шагов и ИМТ. Количество пройденных шагов напрямую связано с уровнем физической активности и энергозатратами. ИМТ, как и в случае с дистанцией ТШХ, может ограничивать достижение более высоких уровней MET. Важно отметить, что такие параметры, как ЧСС, систолическое и диастолическое артериальное давление, продемонстрировали меньшую

значимость. Это может быть связано с их большей вариабельностью и зависимостью от множества факторов, не учтенных в модели.

Клиническая значимость разработанной модели градиентного бустинга заключается в ее потенциальной возможности оптимизировать программы кардиореабилитации. В случаях, когда проведение ВЭМ-пробы затруднено или невозможно (например, у пациентов с тяжелым клиническим состоянием или при отсутствии необходимого оборудования), наша модель может служить ценным вспомогательным инструментом для оценки функциональной работоспособности и планирования индивидуализированных программ тренировок. Это позволит врачам принимать более обоснованные решения об интенсивности физических нагрузок, продолжительности тренировок и других аспектах кардиореабилитации, что в свою очередь может привести к улучшению результатов лечения и повышению безопасности пациентов. Модель также может быть использована для мониторинга прогресса пациентов в процессе кардиореабилитации и своевременной корректировки программы тренировок. Это может способствовать улучшению качества жизни и прогноза выживаемости пациентов с ССЗ.

Основным ограничением настоящего исследования является относительно небольшой объем выборки, что потенциально ограничивает обобщаемость полученных результатов.

Заключение

Проведенное проспективное когортное исследование продемонстрировало эффективность использования современных методов машинного обучения для прогнозирования результатов ВЭМ-пробы на основе данных, полученных в ходе ТШХ. Использование алгоритмов случайного леса, градиентного бустинга, k-ближайших соседей и многофакторной линейной регрессии позволило идентифицировать наиболее информативные признаки, оказывающие влияние на прогнозируемые величины ТШХ и MET.

Установлено, что модель градиентного бустинга обеспечивает наилучшие показатели качества прогноза, характеризующиеся высоким коэффициентом детерминации (R^2 около 0,99) и низкими значениями ошибок (MAE, MSE, RMSE) для обеих целевых метрик. Это подтверждает эффективность выбранного подхода для прогнозирования результатов ВЭМ-пробы на основе данных ТШХ без необходимости проведения дорогостоящих и ресурсоемких проб. Данная методика особенно актуальна в отношении пациентов с тяжелым клиническим состоянием, для которых выполнение максимальных нагрузочных тестов сопряжено с повышенными рисками.

Финансирование. Данное исследование было проведено в рамках выполнения государственного

задания для Ивановского государственного медицинского университета «Дистанционный кардиомониторинг в медицинской реабилитации» (SLFW-2024-0022), номер государственного учета в ЕГИСУ НИОКТР 124031100012-3.

Конфликт интересов. Авторы заявляют об отсутствии конфликта интересов.

Литература/References

1. Gaidai O., Cao Y., Loginov S. Global cardiovascular diseases death rate prediction. *Curr Probl Cardiol* 2023; 48(5): 101622, <https://doi.org/10.1016/j.cprcardiol.2023.101622>.

2. World Health Organization. *Cardiovascular diseases (CVDs)*. 31 July 2025. URL: [https://www.who.int/en/news-room/fact-sheets/detail/cardiovascular-diseases-\(cvds\)](https://www.who.int/en/news-room/fact-sheets/detail/cardiovascular-diseases-(cvds)).

3. Shokri K., Karimian A., Radfar A., Mohammadi A., Amerizadeh A., Karimi R., Sadeghi M. Effect of exercise-based cardiac rehabilitation in patients with acute coronary syndrome: a systematic review and meta-analysis. *BMC Sports Sci Med Rehabil* 2025; 17(1): 233, <https://doi.org/10.1186/s13102-025-01270-8>.

4. Meng Y., Zhuge W., Huang H., Zhang T., Ge X. The effects of early exercise on cardiac rehabilitation-related outcome in acute heart failure patients: a systematic review and meta-analysis. *Int J Nurs Stud* 2022; 130: 104237, <https://doi.org/10.1016/j.ijnurstu.2022.104237>.

5. Mahmood A., Ray R., Bin Salam S.S.T., Haque F., Akkaldevi J., Masmoum M.D., Hassan M.S., Essani B., Anjum T., Mirza M.S.S. The effectiveness of cardiac rehabilitation programs in improving cardiovascular outcomes: systematic review and meta-analysis. *Cureus* 2024; 16(10): e72450, <https://doi.org/10.7759/cureus.72450>.

6. Moghei M., Turk-Adawi K., Isaranuwatthai W., Sarrafzadegan N., Oh P., Chessex C., Grace S.L. Cardiac rehabilitation costs. *Int J Cardiol* 2017; 244: 322–328, <https://doi.org/10.1016/j.ijcard.2017.06.030>.

7. Thomas R.J., Beatty A.L., Beckie T.M., Brewer L.C., Brown T.M., Forman D.E., Franklin B.A., Keteyian S.J., Kitzman D.W., Regensteiner J.G., Sanderson B.K., Whooley M.A. Home-based cardiac rehabilitation: a scientific statement from the American association of cardiovascular and pulmonary rehabilitation, the American Heart Association, and the American College of Cardiology. *Circulation* 2019; 140(1): e69–e89, <https://doi.org/10.1161/CIR.0000000000000663>.

8. *Кардиореабилитация и вторичная профилактика*. Под ред. Аронова Д.М. М: ГЭОТАР-Медиа; 2021, <https://doi.org/10.33029/9704-6218-8-car-2021-1-464>.

Kardioreabilitatsiya i vtorichnaya profilaktika. Pod red. Aronova D.M. [Cardiac rehabilitation and secondary prevention. Aronov D.M. (editor)]. Moscow: GEOTAR-Media; 2021, <https://doi.org/10.33029/9704-6218-8-car-2021-1-464>.

9. Coulshed A., Coulshed D., Pathan F. Systematic review of the use of the 6-minute walk test in measuring and improving prognosis in patients with ischemic heart disease.

CJC Open 2023; 5(11): 816–825, <https://doi.org/10.1016/j.cjco.2023.08.003>.

10. Mikhailovskaya T.V., Nazarova O.A., Dovgalyuk Yu.V., Chistyakova Yu.V., Mishina I.E. Methodological issues of assessment of sixminute walk test in patients with coronary artery disease. *Bulletin of Rehabilitation Medicine* 2021; 20(3): 37–44, <https://doi.org/10.38025/2078-1962-2021-20-3-37-44>.

11. Mapelli M., Salvioni E., Paneroni M., Gugliandolo P., Bonomi A., Scalvini S., Raimondo R., Sciomer S., Mattavelli I., La Rovere M.T., Agostoni P. Brisk walking can be a maximal effort in heart failure patients: a comparison of cardiopulmonary exercise and 6 min walking test cardiorespiratory data. *ESC Heart Fail* 2022; 9(2): 812–821, <https://doi.org/10.1002/ehf2.13781>.

12. Cavero-Redondo I., Saz-Lara A., Bizzozero-Peroni B., Núñez-Martínez L., Díaz-Gofi V., Calero-Paniagua I., Matínez-García I., Pascual-Morena C. Accuracy of the 6-minute walk test for assessing functional capacity in patients with heart failure with preserved ejection fraction and other chronic cardiac pathologies: results of the ExIC-FEP trial and a meta-analysis. *Sports Med Open* 2024; 10(1): 74, <https://doi.org/10.1186/s40798-024-00740-6>.

13. Rasa A.R. Artificial intelligence and its revolutionary role in physical and mental rehabilitation: a review of recent advancements. *Biomed Res Int* 2024; 2024: 9554590, <https://doi.org/10.1155/bmri/9554590>.

14. Norgeot B., Glicksberg B.S., Butte A.J. A call for deep-learning healthcare. *Nat Med* 2019; 25(1): 14–15, <https://doi.org/10.1038/s41591-018-0320-3>.

15. Esteva A., Robicquet A., Ramsundar B., Kuleshov V., DePristo M., Chou K., Cui C., Corrado G., Thrun S., Dean J. A guide to deep learning in healthcare. *Nat Med* 2019; 25(1): 24–29, <https://doi.org/10.1038/s41591-018-0316-z>.

16. Chilamkurthy S., Ghosh R., Tanamala S., Biviji M., Campeau N.G., Venugopal V.K., Mahajan V., Rao P., Warier P. Deep learning algorithms for detection of critical findings in head CT scans: a retrospective study. *Lancet* 2018; 392(10162): 2388–2396, [https://doi.org/10.1016/S0140-6736\(18\)31645-3](https://doi.org/10.1016/S0140-6736(18)31645-3).

17. Ehteshami Bejnordi B., Veta M., Johannes van Diest P., van Ginneken B., Karssemeijer N., Litjens G., van der Laak JAWM; the CAMELYON16 Consortium; Hermsen M., Manson Q.F., Balkenhol M., Geessink O., Stathonikos N., van Dijk M.C., Bult P., Beca F., Beck A.H., Wang D., Khosla A., Gargeya R., Irshad H., Zhong A., Dou Q., Li Q., Chen H., Lin H.J., Heng P.A., Haß C., Bruni E., Wong Q., Halici U., Öner M.Ü., Cetin-Atalay R., Berseth M., Khvatkov V., Vylegzhanin A., Kraus O., Shaban M., Rajpoot N., Awan R., Sirinukunwattana K., Qaiser T., Tsang Y.W., Tellez D., Annuschein J., Hufnagl P., Valkonen M., Kartasalo K., Latonen L., Ruusuvoori P., Liimatainen K., Albarqouni S., Mungal B., George A., Demirci S., Navab N., Watanabe S., Seno S., Takenaka Y., Matsuda H., Ahmady Phoulady H., Kovalev V., Kalinovskiy A., Liauchuk V., Bueno G., Fernandez-Carrobles M.M., Serrano I., Deniz O., Racoceanu D., Venâncio R. Diagnostic assessment of deep learning algorithms for detection of lymph node metastases in women with breast cancer. *JAMA* 2017; 318(22): 2199–2210, <https://doi.org/10.1001/jama.2017.14585>.

18. Zhu M., Chen W., Hirdes J.P., Stolee P. The k-nearest neighbor algorithm predicted rehabilitation potential better than current Clinical Assessment Protocol. *J Clin Epidemiol* 2007; 60(10): 1015–1021, <https://doi.org/10.1016/j.jclinepi.2007.06.001>.
19. Zhu M., Cheng L., Armstrong J.J., Poss J.W., Hirdes J.P., Stolee P. Using machine learning to plan rehabilitation for home care clients: beyond "black-box" predictions. In: Dua S., Acharya U., Dua P. (editors). *Machine learning in healthcare informatics. Intelligent systems reference library, vol 56*. Springer, Berlin, Heidelberg; 2014, https://doi.org/10.1007/978-3-642-40017-9_9.
20. Lin W.Y., Chen C.H., Tseng Y.J., Tsai Y.T., Chang C.Y., Wang H.Y., Chen C.K. Predicting post-stroke activities of daily living through a machine learning-based approach on initiating rehabilitation. *Int J Med Inform* 2018; 111: 159–164, <https://doi.org/10.1016/j.ijmedinf.2018.01.002>.
21. Sharma A., Lysenko A., Jia S., Boroevich K.A., Tsunoda T. Advances in AI and machine learning for predictive medicine. *J Hum Genet* 2024; 69(10): 487–497, <https://doi.org/10.1038/s10038-024-01231-y>.
22. De Cannière H., Corradi F., Smeets CJP, Schoutteten M., Varon C., Van Hoof C., Van Huffel S., Groenendaal W., Vandervoort P. Wearable monitoring and interpretable machine learning can objectively track progression in patients during cardiac rehabilitation. *Sensors (Basel)* 2020; 20(12): 3601, <https://doi.org/10.3390/s20123601>.
23. Desai F., Chowdhury D., Kaur R., Peeters M., Arya R.C., Wander G.S., Gill S.S., Buyya R. HealthCloud: a system for monitoring health status of heart patients using machine learning and cloud computing. *Internet of Things* 2022; 17: 10048, <https://doi.org/10.1016/j.iot.2021.100485>.
24. Alshurafa N., Sideris C., Pourhomayoun M., Kalantarian H., Sarrafzadeh M., Eastwood J.A. Remote health monitoring outcome success prediction using baseline and first month intervention data. *IEEE J Biomed Health Inform* 2017; 21(2): 507–514, <https://doi.org/10.1109/JBHI.2016.2518673>.
25. den Uijl I., van den Berg-Emons R.J.G., Sunamura M., Lenzen M.J., Stam H.J., Boersma E., Tenbült-van Limpt N.C.C.W., Kemps H.M.C., Geleijnse M.L., Ter Hoeve N. Effects of a dedicated cardiac rehabilitation program for patients with obesity on body weight, physical activity, sedentary behavior, and physical fitness: the OPTICARE XL randomized controlled trial. *Phys Ther* 2023; 103(9): pzad055, <https://doi.org/10.1093/ptj/pzad055>.
26. O'Connor F.K., Chen D., Sharma P., Adsett J., Hwang R., Roberts L., Bach A., Louis M., Morris N. Physiological responses to sit-to-stand and six-minute walk tests in heart failure: a randomised trial. *Heart Lung Circ* 2025; 34(8): 789–797, <https://doi.org/10.1016/j.hlc.2025.03.002>.
27. Büsching G., Schmid J.P. 6-minute walk test: exploring factors influencing perceived intensity in older patients undergoing cardiac rehabilitation—a qualitative study. *Healthcare (Basel)* 2025; 13(7): 735, <https://doi.org/10.3390/healthcare13070735>.