



Научно-исследовательский журнал «International Journal of Medicine and Psychology / Международный журнал медицины и психологии»

<https://ijmp.ru>

2025, Том 8, № 7 / 2025, Vol. 8, Iss. 7 <https://ijmp.ru/archives/category/publications>

Научная статья / Original article

Шифр научной специальности: 3.3.8. Клиническая лабораторная диагностика (медицинские науки)

УДК 61:004.8

¹Добренко О.В.,

¹Клиника Зиген, Германия

Методы предоперационного риск-скрининга на основе искусственного интеллекта с использованием анамнеза и лабораторных данных

Аннотация: статья посвящена анализу современных подходов к предоперационному риск-скринингу с использованием алгоритмов искусственного интеллекта, интегрирующих анамнестические и лабораторные данные. Обоснована актуальность перехода от традиционных скоринговых шкал к более точным и адаптивным ИИ-моделям, способным учитывать большое число переменных и выявлять сложные паттерны в клиничко-биохимической информации. В рамках исследования изучены принципы построения предиктивных моделей, включая градиентный бустинг, XGBoost и логистическую регрессию с L1-регуляризацией, а также их интерпретируемость с применением SHAP. Особое внимание уделено обоснованию прогностической ценности таких факторов, как уровень С-реактивного белка, количество предоперационных консультаций, объем перелитой крови, хронические заболевания, пол, возраст, параметры медикаментозной терапии и лабораторные отклонения, которые не включаются в традиционные шкалы. Работа ставит целью систематизировать существующие методики, доказав преимущество моделей ИИ в условиях реального клинического процесса. Для её выполнения использован сравнительный анализ и структурирование научных источников. В заключении показано, что ИИ-скрининг трансформирует практику оценки риска, предлагая персонализированные и воспроизводимые решения. Статья будет полезна специалистам в области хирургии, анестезиологии и медицинской информатики.

Ключевые слова: предоперационный скрининг, машинное обучение, лабораторные данные, прогноз осложнений, SHAP-анализ, анестезиологический риск, электронные истории болезни, персонализированная медицина, интерпретируемость моделей, медицинская аналитика

Для цитирования: Добренко О.В. Методы предоперационного риск-скрининга на основе искусственного интеллекта с использованием анамнеза и лабораторных данных // International Journal of Medicine and Psychology. 2025. Том 8. № 7. С. 15 – 23.

Поступила в редакцию: 7 июня 2025 г.; Одобрена после рецензирования: 5 августа 2025 г.; Принята к публикации: 17 октября 2025 г.

¹Dobrenko O.V.,

¹Siegen Medical Center, Germany

Methods of preoperative risk screening based on artificial intelligence using medical history and laboratory data

Abstract: the article is devoted to the analysis of modern approaches to preoperative risk screening using artificial intelligence algorithms that integrate anamnestic and laboratory data. The relevance of the transition from traditional scoring scales to more accurate and adaptive AI models capable of taking into account a large number of variables and identifying complex patterns in clinical and biochemical information is substantiated. The research examines the principles of predictive model construction, including gradient boosting, XGBoost, and logistic regression with L1 regularization, as well as their interpretability using SHAP. Special attention is paid to substantiating the prognostic value of such factors as the level of C-reactive protein, the number of preoperative consultations,

the volume of blood transfused, chronic diseases, gender, age, parameters of drug therapy and laboratory abnormalities that are not included in traditional scales. The work aims to systematize existing techniques, proving the advantage of AI models in a real clinical process. For its implementation, comparative analysis and structuring of scientific sources were used. In conclusion, it is shown that AI screening transforms the practice of risk assessment by offering personalized and reproducible solutions. The article will be useful for specialists in the field of surgery, anesthesiology and medical informatics.

Keywords: preoperative screening, machine learning, laboratory data, prognosis of complications, SHAP analysis, anesthetic risk, electronic medical records, personalized medicine, interpretability of models, medical analytics

For citation: Dobrenko O.V. Methods of preoperative risk screening based on artificial intelligence using medical history and laboratory data. International Journal of Medicine and Psychology. 2025. 8 (7). P. 15 – 23.

The article was submitted: June 7, 2025; Approved after reviewing: August 5, 2025; Accepted for publication: October 17, 2025

Введение

Предоперационная оценка риска является неотъемлемой частью современной медицины, поскольку позволяет прогнозировать вероятность интра- и послеоперационных осложнений и своевременно принимать меры для их предотвращения. Традиционно риск хирургического вмешательства оценивается на основании клинического анамнеза, физикального статуса пациента и результатов базовых исследований. Широко применяются различные скоринговые системы, например, шкала ASA (American Society of Anesthesiologists Physical Status), а также специализированные расчетные модели риска, такие как калькулятор ACS-NSQIP (Американского колледжа хирургов) или система SURPAS [8]. Однако подобные инструменты имеют ряд ограничений. Так, шкала ASA отличается субъективностью и учитывает лишь обобщенное физическое состояние, игнорируя конкретные важные факторы (возраст, сопутствующие заболевания, лабораторные показатели). Более сложные калькуляторы (NSQIP, SURPAS) учитывают больше переменных, но требуют ручного ввода данных и могут быть трудоемки в практическом применении. В условиях дефицита времени в предоперационной подготовке, особенно при экстренных операциях, клиницисту трудно оперативно обработать весь объем разнородной информации об анализе и результатах анализов пациента.

В последние годы в предоперационный риск-скрининг активно внедряются методы искусственного интеллекта (ИИ), прежде всего алгоритмы машинного обучения, способные автоматически анализировать большие массивы данных истории болезни и лабораторных исследований. Применение ИИ позволяет создавать прогнозные модели, которые по совокупности параметров пациента оценивают вероятность развития определенных

осложнений или неблагоприятных исходов операции с более высокой точностью, чем традиционные подходы. Машинное обучение предоставляет возможность учитывать десятки и сотни параметров – демографических, клинических, лабораторных – выявляя скрытые нелинейные зависимости, недоступные человеческому взгляду. Это особенно актуально в предоперационном периоде, где решение о тактике ведения пациента (например, необходимости более интенсивного мониторинга или профилактических мероприятий) основывается на точности прогноза риска.

Цель данной статьи – провести анализ современных методов предоперационного риск-скрининга на основе искусственного интеллекта, которые используют данные анамнеза и лабораторных исследований.

Материалы и методы исследований

Для подготовки статьи использован комплекс научных публикаций, отражающих современное состояние исследований в области применения искусственного интеллекта в предоперационном прогнозировании. Л.В. Липидус и О.М. Токарева [1] систематизировали направления внедрения ИИ в медицинские услуги, предложив таксономию решений для интеграции алгоритмов в клинический процесс. В.С. Переверзев, А.И. Казьмин, М.Л. Сажнев, А.А. Пантелеев и С.В. Колесов [2] выполнили систематический обзор применения ИИ в вертебрологии, выявив факторы, влияющие на прогнозирование осложнений. А.А. Пранович, А.К. Исмаилов, Н.А. Карельская и соавт. [3] рассмотрели возможности ИИ в диагностике и лечении мочекаменной болезни, показав эффективность алгоритмов в обработке комплексных данных. Ш.Л. Шайлиева, Д.Х. Мамчуева, А.П. Вишневская и др. [4] проанализировали использование ИИ в гинекологии, описав модели с высокой прогностической точностью. P. Arina, M.R. Kaczorek,

D.A. Hofmaenner и коллеги [5] провели систематическую оценку алгоритмов машинного обучения в периоперационной медицине, применив критерии PROBAST. K.M. Corey, S. Kashyap, E. Lorenzi и др. [6] разработали и верифицировали модель Pythia для автоматической стратификации хирургических рисков на основе электронных историй болезни. M. Graefner, B. Jungwirth, E. Frank и соавт. [7] создали модель персонализированного предсказания риска на базе предоперационных данных. Y.Y. Li, J.J. Wang, S.H. Huang и др. [8] внедрили алгоритм машинного обучения для оценки риска при операции по фиксации перелома бедра. A. Mahajan, S. Esper, T.H. Oo и коллеги [9] предложили и апробировали модель ИИ для прогнозирования послеоперационных неблагоприятных исходов. Q. Yu, M. Fu, Z. Hou и соавт. [10] выявили предикторы предоперационной острой сердечной недостаточности у пожилых пациентов с переломом бедра, применив SHAP-анализ.

В работе применены сравнительный метод, структурный анализ и синтез данных научных источников, а также систематизация опубликованных результатов для формирования целостной картины применения ИИ в предоперационном риск-скрининге. Итогом анализа стало выявление общих принципов построения, валидации и интерпретации моделей, а также факторов, определяющих перспективность их внедрения в клиническую практику.

Результаты и обсуждения

Современные исследования убедительно демонстрируют преимущество алгоритмов искусственного интеллекта в предоперационном прогнозировании рисков по сравнению с традиционными шкалами и ручными расчетами. Во-первых, модели машинного обучения показывают значительно более высокую точность стратификации риска осложнений. Например, в исследовании был разработан предиктивный алгоритм для пациентов с переломом бедра, основанный на 22 переменных (анамнез, коморбидность, основные лабораторные показатели). Полученная модель предсказания послеоперационных осложнений существенно пре-

взошла по точности классическую оценку ASA: площадь под ROC-кривой (AUROC) составила 0,810 против 0,629 у шкалы ASA-PS ($p < 0,01$) при прогнозировании комбинированного неблагоприятного исхода [8]. Аналогичное превосходство модели ИИ отмечено и для других конечных точек – необходимость перевода в реанимацию и удлиненный послеоперационный стационар – где AUROC алгоритма также была ~0,83 против ~0,69 у оценки ASA [8]. Эти результаты свидетельствуют, что ИИ, обрабатывая множество параметров пациента, способен более точно идентифицировать группу высокого риска, чем человеческая оценка по обобщенной шкале.

Во-вторых, интеграция данных анамнеза и лабораторных тестов через алгоритмы ИИ позволяет предсказывать не только общие осложнения, но и специфические риски. Машинное обучение успешно применено для прогнозирования отдельных послеоперационных событий: например, острой почечной недостаточности после кардиохирургических операций, развития острой сердечной недостаточности у пожилых пациентов с переломом шейки бедра, дыхательных осложнений и др. В каждом из этих случаев модели, обученные на ретроспективных данных, продемонстрировали высокую чувствительность и специфичность. Так, алгоритм на основе XGBoost, разработанный в 2023 г. группой исследователей Мюнхенского технического университета, сумел предсказать 30-дневную послеоперационную смертность с AUROC ~0,95 на валидационной выборке (~67 тысяч случаев), при этом в список наиболее значимых предикторов вошли возраст, уровень С-реактивного белка, объем предоперационно перелитой крови и ряд других лабораторно-клинических показателей [7]. Примечательно, что многие из топ-факторов, выявленных этой моделью, не входят напрямую в стандартные шкалы риска, что подчеркивает ценность комплексного учета анамнеза и анализов. Ниже представлена систематизация значимых переменных, наиболее часто отобранных ИИ-моделями при прогнозировании послеоперационных осложнений (табл. 1).

Таблица 1

Типология параметров, определяющих высокий предоперационный риск в ИИ-моделях (составлено автором на основе [1, 3, 6, 8, 10]).

Table 1

Typology of parameters determining high preoperative risk in AI models (compiled by the author based on [1, 3, 6, 8, 10]).

Категория параметров	Характеристика переменных	Примеры из практических моделей
Демографические	Общие сведения о пациенте, увеличивающие вероятность неблагоприятного исхода	Возраст, пол, индекс массы тела, социальный статус
Анамнестические	Информация о сопутствующих заболеваниях и истории болезни пациента	Хроническая сердечная недостаточность, диабет, гипертензия
Лабораторные	Показатели биохимии крови и другие стандартные маркеры	Уровень креатинина, гемоглобин, С-реактивный белок, электролиты
Фармакологические	Используемые пациентом препараты, влияющие на течение послеоперационного периода	Приём антикоагулянтов, инсулина, иммуносупрессоров
Логистические/организационные	Внутрибольничные параметры, отражающие сложность случая	Количество консультаций перед операцией, срочность вмешательства

В-третьих, ИИ-модели демонстрируют высокую устойчивость и сохраняют точность при внешней проверке [1, 4]. Одним из крупнейших на сегодняшний день исследований является работа из Университета Питтсбурга, где была создана прогностическая модель на основе градиентного бустинга для выявления пациентов с высоким риском неблагоприятных исходов на основе данных электронных историй болезни хирургических пациентов. Эта модель, обученная на большом мультицентровом датасете, достигла превосходных результатов: AUROC для предсказания госпитальной смертности составила 0,95 на тестовой выборке и 0,956 при проспективном внедрении в клинику [9]. Для комбинированной конечной точки (большие сердечно-сосудистые осложнения или смерть) точность также была очень высокой (AUROC ~0,90). Важно, что предложенный алго-

ритм превзошел по эффективности уже существующий в практике калькулятор риска ACS-NSQIP [9]. Такой прирост на большой выборке – существенный показатель, означающий заметное улучшение способности распознавать пациентов в зоне риска. Более того, модель прошла проспективную валидацию: ее внедрили в реальное время в клинический процесс сети больниц UPMC, подтвердив тем самым практическую применимость – алгоритм автоматически идентифицировал перед операцией пациентов группы высокого риска, что позволяло врачам заблаговременно усиливать мониторинг и профилактику. Для наглядного представления возможностей интеграции ИИ-алгоритмов в клинические процессы проводится обобщённая схема сценариев применения моделей в предоперационной практике (табл. 2).

Таблица 2

Варианты применения ИИ-моделей в процессе подготовки пациента к операции (составлено автором на основе [5-7, 9]).

Table 2

Application options for AI models in the process of preparing a patient for surgery (compiled by the author based on [5-7, 9]).

Этап медицинского процесса	Возможности ИИ-модели	Прогностический результат
Первичное поступление пациента	Быстрая автоматическая стратификация риска по данным электронной карты	Выявление скрытых факторов риска
Предоперационный консилиум	Поддержка принятия решения по выбору объема и характера хирургии	Предотвращение нежелательных вмешательств
Планирование интенсивного мониторинга	Выбор пациентов, требующих ИТ-поддержки на основе прогноза риска	Снижение вероятности острых осложнений в послеоперационном периоде

Продолжение таблицы 2
Continuation of Table 2

Персонализация анестезиологической тактики	Определение рисков гемодинамической нестабильности	Более точная подготовка и выбор метода анестезии
Документация и информирование	Создание прогностических отчётов для включения в ИБ и передачи пациенту	Повышение прозрачности и доверия к прогнозу

В-четвертых, применение методов ИИ расширяет диапазон учитываемых предикторов и обеспечивает персонифицированный подход к оценке риска [3]. Традиционные модели, как правило, опираются на ограниченный набор входных данных, тогда как алгоритмы машинного обучения могут обрабатывать сотни переменных. Например, в проекте Pythia (Duke University, 2018) был создан автоматизированный репозиторий данных, включающий 194 признака на каждого пациента (демография, сопутствующие заболевания, лекарства, параметры операции и т.д.), на основе которых обучались модели для прогноза осложнений. На тестовых данных эти модели показали AUROC от 0,75 до 0,92 в зависимости от категории исхода [6]. Наиболее успешная модель (логистическая регрессия с L1-регуляризацией) достигла AUROC ~0,924 в прогнозе шока, что значительно лучше по сравнению с существующими подходами, и позволила внедрить в клинику автоматический калькулятор риска по 14 типам осложнений [6]. Таким образом, ИИ дает возможность учесть совокупное влияние множества факторов анамнеза и лабораторных данных на исход – вплоть до таких нюансов, как комбинации нескольких хронических болезней или взаимосвязь определенных отклонений лабораторных показателей, – что ведет к более тонкому и точному прогнозу для конкретного пациента.

В-пятых, несмотря на обнадеживающие успехи, анализ литературы выявляет и проблемные зоны в применении ИИ для предоперационного риск-скрининга. Систематический обзор, охвативший 103 исследования машинного обучения в периоперационной медицине, показал, что лишь 13% разработанных моделей прошли внешнюю мультицентровую валидацию [5]. Большинство работ были ограничены данными одного центра, и нередко модели грешили переобученностью под конкретную выборку.

Кроме того, прогностическая способность мно-

гих опубликованных моделей смертности оказалась скромной либо сопоставимой с существующими клиническими шкалами, что указывает на разношерстное качество исследований в этой сфере [5]. Тем не менее даже в этом обзоре отмечается ряд высокоточных моделей (как упомянутые выше питтсбургская и др.), которые обладают реальным потенциалом применения. Важным аспектом, подчеркнутым в литературе, является необходимость балансировки между сложностью модели и ее интерпретируемостью: методы глубокого обучения, дающие порой наивысшую точность, трудны для понимания врачом, тогда как более простые алгоритмы (логистическая регрессия, решающие деревья) обеспечивают объяснимость результатов, что критично в медицине. Отдельные исследования применяют технологии интерпретации моделей – например, анализ SHAP (Shapley Additive Explanations) для оценки вклада каждого признака в прогноз, – что помогает врачам понять, какие именно данные анамнеза или анализа обусловили высокий риск у пациента [10].

Представленные работы демонстрируют, что алгоритмы машинного обучения способны превосходить устоявшиеся шкалы по качеству стратификации рисков, расширяя границы персонификации оценок и обеспечивая высокую устойчивость показателей при внешней проверке. Высокие значения AUROC для различных моделей подчёркивают потенциал комплексного анализа клинико-лабораторных данных с учётом ретроспективных и проспективных валидаций [2]. Одновременно следует учитывать компромисс между точностью и прозрачностью алгоритмов: применение методов интерпретируемости, например анализа SHAP, представляется практичным путём повышения доверия клиницистов к решениям ИИ. Ниже приведена сравнительная характеристика алгоритмов машинного обучения по параметрам применимости в клинической среде (табл. 3).

Таблица 3

Сравнительный анализ алгоритмов машинного обучения по применимости в медицине (составлено автором на основе [5, 6, 8]).

Table 3

Comparative analysis of machine learning algorithms for applicability in medicine (compiled by the author based on [5, 6, 8]).

Алгоритм	Достоинства	Ограничения	Подходит для внедрения в клинику
Логистическая регрессия	Простота интерпретации, высокая объяснимость	Ограниченная точность при сложных нелинейных взаимосвязях	Да
Решающее дерево	Быстрая визуализация, позволяет видеть структуру принятия решений	Склонность к переобучению, нестабильность при изменении данных	Частично
XGBoost	Высокая точность, устойчивость к шуму	Трудность интерпретации, требует вычислительных ресурсов	Да
Глубокие нейросети	Способность выявлять сложные зависимости	“Чёрный ящик”, необходимость в больших данных	Нет (без SHAP/LIME)
Метод опорных векторов (SVM)	Эффективность при малых объёмах данных	Низкая масштабируемость, сложность понимания выходных данных	Ограниченно

Расширение мультицентровых исследований и дальнейшая интеграция адаптивных моделей в клинические рабочие процессы представляют область приоритетного научного поиска. Поэтому можно полагать, что сочетание углублённого машинного обучения с инструментами объяснимости создаст новые возможности для индивидуального предоперационного скрининга и снизит частоту неблагоприятных исходов.

Результаты обзора свидетельствуют, что использование искусственного интеллекта, опирающегося на данные анамнеза и лабораторных показателей, выводит предоперационный риск-скрининг на качественно новый уровень. Повышение точности прогнозов имеет глубокое практическое значение: более раннее и точное выявление “группы риска” позволяет индивидуализировать ведение пациента. В клинической практике это означает, что пациентов с высоким предсказанным риском осложнений можно направить на углубленное обследование (например, дополнительная кардиологическая оценка), оптимизировать их состояние до операции (коррекция анемии, компенсация хронических заболеваний), планировать операцию с участием более опытной бригады или в присутствии реаниматолога, зарезервировать койку в отделении интенсивной терапии и т.д. Тем самым улучшаются конечные результаты лечения. Крупное исследование показало, что внедрение автоматизированной модели ИИ в сеть стационаров действительно приводит к изменению клинической тактики: врачи получают предупреждения о высоком риске и могут своевременно

вмешаться. Это подчёркивает, что ИИ-инструменты способны не только предсказывать, но и менять поведение клиницистов, становясь частью системы поддержки принятия решений.

Анализ факторов, которые выявляют модели ИИ, также дает ценные инсайты. Интересно, что алгоритмы практически во всех исследованиях подтверждают значимость известных клинике показателей (возраст, сопутствующие заболевания, функциональное состояние, ключевые лабораторные маркеры, например уровень гемоглобина или креатинина). Однако, помимо этого, они выделяют и менее очевидные признаки риска. Например, упомянутая модель указала на количество назначенных предоперационных консультаций профильных специалистов как один из важных предикторов летального исхода. Логически это отражает сложность состояния пациента: чем больше потребовалось консилиумов и консультаций (кардиолога, эндокринолога и т.д.), тем вероятно тяжелее больной, хотя напрямую это не входит в стандартные шкалы. Такие находки расширяют наше понимание факторов риска. Кроме того, использование лабораторных данных (например, уровень С-реактивного белка, показатели печени, электролиты) позволяет моделям улавливать биохимические индикаторы уязвимости пациента, которые ранее могли недооцениваться. ИИ способен обнаружить сложные нелинейные связи: скажем, комбинация умеренно повышенного креатинина, легкой анемии и диабета в сумме резко повышает риск, хотя каждый из этих факторов по отдельности не критичен. Для врача подобный

вывод не всегда очевиден, а модель его формализует. В итоге, клиницист, пользуясь выводами ИИ, получает более полную картину состояния пациента, что способствует лучшей подготовке к операции.

Внедрение ИИ в предоперационную практику сталкивается и с вызовами. Во-первых, нужны большие тщательно собранные датасеты, интегрирующие все данные о пациенте – от истории болезни до результатов анализов – в машиночитаемом формате. Пока не все лечебные учреждения имеют такие электронные системы. Во-вторых, важно обеспечить валидность и обобщаемость моделей: алгоритм, обученный на данных одной клиники, может терять точность в другой популяции из-за иных протоколов лечения или характеристик пациентов. Поэтому актуальна разработка многоцентровых моделей или адаптивных алгоритмов, умеющих дообучаться под новую среду. В-третьих, необходимо преодолеть «черный ящик» ИИ – добиться доверия со стороны врачей. Здесь помогают методы интерпретации (SHAP, LIME и др.), визуализация значимости признаков, а также включение врачей в процесс разработки модели (чтобы она учитывала клинически осмысленные параметры).

Наконец, следует отметить, что ИИ-скрининг риска призван не заменить врача, а усилить его возможности. Решение о лечении остается за клиницистом; алгоритм лишь предоставляет дополнительный инструмент, иногда указывая на нетривиальные угрозы. Например, модель может подсказать, что относительно “здоровый” на первый взгляд пациент имеет скрытый высокий риск на основе сочетания показателей – это послужит сигналом более внимательно обследовать его перед операцией. Таким образом, сотрудничество человека и ИИ позволяет достичь наилучших результатов: врач задает правильные вопросы и контролирует процесс, а машина быстро обрабатывает данные и предлагает прогноз.

С течением времени и накоплением опыта использования ИИ в предоперационном менеджменте можно ожидать повышения точности и надежности моделей. По мере включения все новых типов данных – генетических, данных изображений (например, результатов ЭхоКГ, КТ) – прогнозы станут еще более персонализированными. Однако уже сейчас, исходя из проанализированных работ, ясно, что ИИ-методы превосходят по эффективности устаревшие подходы и постепенно будут интегрированы в стандарты предоперационной подготовки.

Выводы

Искусственный интеллект, обрабатывающий данные анамнеза и результаты лабораторных исследований, продемонстрировал высокую эффективность в задаче предоперационного риск-скрининга. Проведенный обзор показал, что модели машинного обучения способны более точно предсказывать вероятность послеоперационных осложнений и летальных исходов, чем традиционные клинические оценки. В количественном отношении это выражается в существенном увеличении площади ROC-кривой (AUROC) прогностических моделей ИИ по сравнению с классическими скоринговыми системами. Научная новизна таких результатов заключается в применении передовых алгоритмов анализа данных для решения медико-клинической проблемы прогнозирования, что открывает новую эру в персонализированной периоперационной медицине.

Практическая значимость внедрения ИИ-скрининга огромна. Благодаря более точной стратификации риска врачи могут заблаговременно идентифицировать пациентов, требующих усиленного внимания, и адаптировать план лечения: проводить коррекцию выявленных отклонений, планировать дополнительные ресурсы (например, реанимационное сопровождение), выбирать оптимальный момент и метод операции. В конечном счете это приводит к снижению частоты осложнений и улучшению исходов хирургического лечения. Кроме того, автоматизация процесса оценки риска экономит время медицинского персонала и стандартизирует подход, минимизируя человеческий фактор в анализе сложной информации.

Основные выводы данной работы сводятся к тому, что методы ИИ, анализирующие совокупность анамнестических и лабораторных данных, уже доказали свою состоятельность и превосходят традиционные подходы по точности и интегральной пользе. Для дальнейшего развития направления необходимо масштабировать исследования, повышать интерпретируемость моделей и интегрировать их в клинические информационные системы. Тем не менее, уже сейчас очевидно, что искусственный интеллект станет неотъемлемой частью предоперационного этапа, помогая врачам принимать более обоснованные решения и повышая безопасность пациентов. Иными словами, сочетание классических знаний врача с вычислительной мощностью и проницательностью ИИ обеспечивает новый уровень качества предоперационной подготовки, что имеет огромное значение как с научной, так и с практической точки зрения для современной хирургии.

Список источников

1. Лapidус Л.В., Токарева О.М. Разработка таксономии решений на основе технологий искусственного интеллекта в практике оказания медицинских услуг // Экономика и управление. 2024. № 7. С. 819 – 831. URL: <https://cyberleninka.ru/article/n/razrabotka-taksonomii-resheniy-na-osnove-tehnologiy-iskusstvennogo-intellekta-v-praktike-okazaniya-meditsinskih-uslug> (дата обращения: 28.04.2025)
2. Переверзев В.С., Казьмин А.И., Сажнев М.Л., Пантелеев А.А., Колесов С.В. Искусственный интеллект для прогнозирования различных состояний в вертебрологии: систематический обзор // Гений ортопедии. 2021. № 6. С. 813 – 818. URL: <https://cyberleninka.ru/article/n/iskusstvennyy-intellekt-dlya-prognozirovaniya-razlichnyh-sostoyaniy-v-vertebrologii-sistematicheskii-obzor> (дата обращения: 29.04.2025)
3. Пранович А.А., Исмаилов А.К., Карельская Н.А. и др. Искусственный интеллект в диагностике и лечении мочекаменной болезни // Журнал телемедицины и электронного здравоохранения. 2022. № 1. С. 42 – 57. URL: <https://cyberleninka.ru/article/n/iskusstvennyy-intellekt-v-dagnostike-i-lechenii-mochekamennoy-bolezni> (дата обращения: 27.04.2025)
4. Шайлиева Ш.Л., Мамчуева Д.Х., Вишневская А.П. и др. Возможности применения искусственного интеллекта в современной гинекологии // Акушерство, гинекология и репродукция. 2024. Т. 18. № 4. С. 563 – 580. DOI: <https://doi.org/10.17749/2313-7347/ob.gyn.rep.2024.511>
5. Arina P., Kaczorek M.R., Hofmaenner D.A. et al. Prediction of Complications and Prognostication in Perioperative Medicine: A Systematic Review and PROBAST Assessment of Machine Learning Tools // Anesthesiology. 2024. Vol. 140. No. 1. P. 85 – 101. DOI: 10.1097/ALN.0000000000004764
6. Corey K. M., Kashyap S., Lorenzi E. et al. Development and validation of machine learning models to identify high-risk surgical patients using automatically curated electronic health record data (Pythia): A retrospective, single-site study // PLOS Medicine. 2018. Vol. 15. No. 11. P. e1002701. DOI: <https://doi.org/10.1371/journal.pmed.1002701>
7. Graefner M., Jungwirth B., Frank E. et al. Enabling personalized perioperative risk prediction by using a machine-learning model based on preoperative data // Scientific Reports. 2023. Vol. 13. P. 7128. DOI: <https://doi.org/10.1038/s41598-023-33981-8>
8. Li Y.Y., Wang J.J., Huang S.H. et al. Implementation of a machine learning application in preoperative risk assessment for hip repair surgery // BMC Anesthesiology. 2022. Vol. 22. P. 116. DOI: <https://doi.org/10.1186/s12871-022-01648-y>
9. Mahajan A., Esper S., Oo T. H. et al. Development and Validation of a Machine Learning Model to Identify Patients Before Surgery at High Risk for Postoperative Adverse Events // JAMA Network Open. 2023. Vol. 6. No. 7. P. 85. DOI: 10.1001/jamanetworkopen.2023.22285
10. Yu Q., Fu M., Hou Z. et al. Elucidating predictors of preoperative acute heart failure in older people with hip fractures through machine learning and SHAP analysis: a retrospective cohort study // BMC Geriatrics. 2025. Vol. 25. P. 268. DOI: <https://doi.org/10.1186/s12877-025-05920-x>

References

1. Lapidus L.V., Tokareva O.M. Development of a taxonomy of decisions based on artificial intelligence technologies in the practice of providing medical services. Economy and Management. 2024. No. 7. P. 819 – 831. URL: <https://cyberleninka.ru/article/n/razrabotka-taksonomii-resheniy-na-osnove-tehnologiy-iskusstvennogo-intellekta-v-praktike-okazaniya-meditsinskih-uslug> (date of access: 04.28.2025)
2. Pereverzev V.S., Kazmin A.I., Sazhnev M.L., Panteleev A.A., Kolesov S.V. Artificial intelligence for predicting various conditions in vertebrology: a systematic review. Genius of Orthopedics. 2021. No. 6. P. 813 – 818. URL: <https://cyberleninka.ru/article/n/iskusstvennyy-intellekt-dlya-prognozirovaniya-razlichnyh-sostoyaniy-v-vertebrologii-sistematicheskii-obzor> (date of access: 04.29.2025)
3. Pranovich A.A., Ismailov A.K., Karelskaya N.A. et al. Artificial intelligence in the diagnosis and treatment of urolithiasis. Journal of Telemedicine and Electronic Health. 2022. No. 1. P. 42 – 57. URL: <https://cyberleninka.ru/article/n/iskusstvennyy-intellekt-v-dagnostike-i-lechenii-mochekamennoy-bolezni> (date of access: 04.27.2025)
4. Shailieva Sh.L., Mamchueva D.Kh., Vishnevskaya A.P. et al. Possibilities of using artificial intelligence in modern gynecology. Obstetrics, gynecology and reproduction. 2024. T. 18. No. 4. P. 563 – 580. DOI: <https://doi.org/10.17749/2313-7347/ob.gyn.rep.2024.511>
5. Arina P., Kaczorek M.R., Hofmaenner D.A. et al. Prediction of Complications and Prognostication in Perioperative Medicine: A Systematic Review and PROBAST Assessment of Machine Learning Tools. Anesthesiology. 2024. Vol. 140.No. 1. P. 85 – 101. DOI: 10.1097/ALN.0000000000004764

6. Corey K. M., Kashyap S., Lorenzi E. et al. Development and validation of machine learning models to identify high-risk surgical patients using automatically curated electronic health record data (Pythia): A retrospective, single-site study. *PLOS Medicine*. 2018. Vol. 15. No. 11. P. e1002701. DOI: <https://doi.org/10.1371/journal.pmed.1002701>
7. Graefner M., Jungwirth B., Frank E. et al. Enabling personalized perioperative risk prediction by using a machine-learning model based on preoperative data. *Scientific Reports*. 2023. Vol. 13. P. 7128. DOI: <https://doi.org/10.1038/s41598-023-33981-8>
8. Li Y.Y., Wang J.J., Huang S.H. et al. Implementation of a machine learning application in preoperative risk assessment for hip repair surgery. *BMC Anesthesiology*. 2022. Vol. 22. P. 116. DOI: <https://doi.org/10.1186/s12871-022-01648-y>
9. Mahajan A., Esper S., Oo T. H. et al. Development and Validation of a Machine Learning Model to Identify Patients Before Surgery at High Risk for Postoperative Adverse Events. *JAMA Network Open*. 2023. Vol. 6. No. 7. P. 85. DOI: [10.1001/jamanetworkopen.2023.22285](https://doi.org/10.1001/jamanetworkopen.2023.22285)
10. Yu Q., Fu M., Hou Z. et al. Elucidating predictors of preoperative acute heart failure in older people with hip fractures through machine learning and SHAP analysis: a retrospective cohort study. *BMC Geriatrics*. 2025. Vol. 25. P. 268. DOI: <https://doi.org/10.1186/s12877-025-05920-x>

Информация об авторе

Добренко О.В., врач-анестезиолог-реаниматолог, Клиника Зиген, Германия, dobrenkoooly@gmail.com

© Добренко О.В., 2025