

УДК 004.89

DOI: [10.26102/2310-6018/2026.55.4.020](https://doi.org/10.26102/2310-6018/2026.55.4.020)

Моделирование и оптимизация процесса сбора данных для искусственного интеллекта в медицине

А.В. Ивашенко¹, М.А. Терехин¹✉, Г.Ю. Порецкова¹, Г.Э. Жданович²,
Д.А. Мельников³, Д.Е. Радаев³

¹Самарский государственный медицинский университет, Самара,
Российская Федерация

²Приволжский государственный университет путей сообщения, Самара,
Российская Федерация

³Пензенский государственный технологический университет, Пенза,
Российская Федерация

Резюме. Развитие технологий искусственного интеллекта в медицине требует реализации системного подхода по сбору и обработке структурированных наборов данных (датасетов) для обучения, тестирования и валидации моделей машинного обучения. В статье предложено решение этой задачи путем имитационного моделирования на основе теории массового обслуживания, в ходе которого необходимо оценить плановую пропускную способность каждой точки сбора информации, обеспечение достаточного количества пациентов, доступности и достоверности их медицинской информации, обеспечение требований законодательства в части защиты персональных данных и врачебной этики. Исследование предложенного подхода было произведено на примере анализа процессов сбора биомедицинских данных, предназначенных для обучения моделей искусственного интеллекта методами дистанционной диагностики. Эмпирическая часть исследования проводилась на базе пунктов сбора биомедицинских сигналов в течение шести месяцев. Общий объем выборки составил 574 пациента. В рамках исследования была построена имитационная модель, позволившая провести оптимизацию процесса сбора данных. По данным имитационного моделирования средняя интенсивность сбора данных составила 7,28 пациента в день при выраженной вариативности нагрузки. В ходе оптимизации были произведены изменения в процессе сбора данных путем распараллеливания, что позволило повысить производительность за счет сокращения времени на анкетирование и термометрию и увеличения входящего потока пациентов. Проведенная оптимизация процесса сбора данных позволила повысить интенсивность работы с 4,67 до 12,12 пациентов в день. Предложенный подход позволяет обосновать архитектуру организационно-технологического процесса сбора информации до начала масштабирования и минимизировать риски превышения календарных сроков формирования медицинских датасетов.

Ключевые слова: медицинский датасет, имитационное моделирование, теория массового обслуживания, цифровой двойник, пропускная способность, искусственный интеллект.

Для цитирования: Ивашенко А.В., Терехин М.А., Порецкова Г.Ю., Жданович Г.Э., Мельников Д.А., Радаев Д.Е. Моделирование и оптимизация процесса сбора данных для искусственного интеллекта в медицине. *Моделирование, оптимизация и информационные технологии.* 2026;14(4). URL: <https://moitvvt.ru/ru/journal/article?id=2232> DOI: 10.26102/2310-6018/2026.55.4.020

Modeling and optimization of data collection process for artificial intelligence in medicine

A.V. Ivaschenko¹, M.A. Terekhin¹✉, G.Yu. Poretskova¹, G.E. Zhdanovich²,
D.A. Melnikov³, D.E. Radaev³

¹Samara State Medical University, Samara, the Russian Federation

²Volga State Transport University, Samara, the Russian Federation
³Penza State Technological University, Penza, the Russian Federation

Abstract. Development of Artificial Intelligence technologies in medicine requires a systematic approach to collecting and processing structured datasets for training, testing, and validating machine learning models. This paper proposes a solution to this problem through simulation modeling based on queueing theory. This modeling requires estimating the planned throughput of each data collection point, ensuring a sufficient number of patients, the availability and reliability of their medical information, and meeting legal requirements regarding personal data protection and medical ethics. The proposed approach was studied using the analysis of biomedical data collection processes designed to train artificial intelligence models for remote diagnostic methods. The empirical part of the study was conducted at biomedical signal collection points over a six-month period. The total sample size was 574 patients. A simulation model was developed to optimize the data collection process. According to the simulation modeling, the average data collection intensity was 7.28 patients per day with significant variability in the workload. During the optimization process, changes were made to the data collection process through parallelization, which increased productivity by reducing the time spent on questionnaires and temperature measurements and increasing patient throughput. The optimization of the data collection process increased the workload from 4.67 to 12.12 patients per day. The proposed approach allows us to validate the architecture of the organizational and technological process for data collection before scaling and minimizes the risk of exceeding the schedule deadlines for generating medical datasets.

Keywords: medical dataset, simulation modeling, queueing theory, digital twin, throughput, artificial intelligence.

For citation: Ivaschenko A.V., Terekhin M.A., Poretskova G.Yu., Zhdanovich G.E., Melnikov D.A., Radaev D.E. Modeling and optimization of data collection process for artificial intelligence in medicine. *Modeling, Optimization and Information Technology*. 2026;14(4). (In Russ.). URL: <https://moitvivr.ru/journal/article?id=2232> DOI: 10.26102/2310-6018/2026.55.4.020

Введение

Развитие цифрового здравоохранения требует системного подхода по организации процессов формирования медицинских данных, предназначенных для обучения систем искусственного интеллекта. Одной из ключевых задач становится организация технологического процесса сбора биомедицинской информации таким образом, чтобы обеспечивались воспроизводимость, стандартизованность и масштабируемость получаемых выборок.

Эффективность интеллектуальных диагностических моделей определяется не только алгоритмической архитектурой, но и качеством исходных данных, их структурированностью и соответствием установленным требованиям к описанию и валидации [1]. Вопросы систематизации и унификации медицинских наборов данных рассматриваются как необходимое условие обеспечения корректности машинного обучения и сопоставимости результатов исследований [2]. Дополнительные ограничения на процесс формирования выборок накладываются нормативными аспектами регулирования использования медицинских данных [3].

Международные исследования подчеркивают значение стандартов описания и метрик оценки качества медицинских датасетов, ориентированных на задачи искусственного интеллекта [4]. Формализованные подходы к оценке пригодности данных для алгоритмической обработки предполагают учет полноты, согласованности и устойчивости измерений [5]. При этом основное внимание в научной литературе уделяется постфактум-анализу уже сформированных выборок, тогда как организационно-технологические аспекты их накопления рассматриваются фрагментарно.

Процесс сбора медицинских данных представляет собой сложную систему, включающую последовательность административных и инструментальных процедур, взаимодействие пациента и персонала, а также использование диагностического оборудования с ограниченной пропускной способностью. Интенсивность входящего потока пациентов носит стохастический характер, а временные параметры отдельных этапов обслуживания подвержены вариациям. Аналогичные по структуре организационно-технологические системы формирования медицинских данных описаны в исследованиях, посвящённых масштабным клиническим наборам и их инфраструктуре [6]. В условиях подобной архитектуры целесообразно рассматривать пункт сбора данных как систему массового обслуживания с ограниченными ресурсами [7, 8].

Под оптимизацией процесса в системе массового обслуживания понимают минимизацию времени ожидания, вероятности отказа или операционных издержек при заданном уровне обслуживания [9, 10]. В рассматриваемой задаче под оптимизацией процесса сбора медицинской информации у группы пациентов будем считать максимизацию количества обслуженных пациентов при ограничении на количество отказов и сохранении качества выполнения диагностических процедур. Это означает достижение максимального ежедневного объема валидной собираемой информации при требуемом ее качестве.

Методы формализации и структурирования медицинских данных, обеспечивающие их повторное использование и интероперабельность [11], создают предпосылки для применения дискретно-событийного моделирования с целью анализа загрузки и выявления узких мест процесса. Отсутствие количественно обоснованной модели пропускной способности затрудняет планирование сроков формирования медицинских датасетов и масштабирование проектов. Организационные решения нередко принимаются на основе экспертных оценок, что повышает риск превышения календарных и ресурсных ограничений.

В связи с этим целью настоящего исследования является разработка и эмпирическая валидация имитационной модели процесса сбора медицинских данных, позволяющей определить предельную пропускную способность системы, оценить влияние стохастических факторов на производительность и обосновать мероприятия по оптимизации архитектуры процесса формирования датасета для задач искусственного интеллекта.

Материалы и методы

Процесс сбора и составления структурированных наборов данных (датасетов) для обучения, тестирования и валидации моделей машинного обучения в настоящее время является одним из ключевых и распространенных этапов внедрения искусственного интеллекта в медицине. При организации такого процесса обычно руководствуются требованиями качества, такими как достоверность и адекватность. Однако не менее важным аспектом организации такого процесса является производительность точек сбора медицинских данных, существенно влияющая на целостность собранных данных и единообразие диагностических процедур.

В качестве основного метода повышения производительности процессов сбора медицинских датасетов можно предложить проведение предварительного имитационного моделирования, в ходе которого необходимо оценить плановую пропускную способность каждой точки сбора информации, обеспечение достаточного количества пациентов, доступности и достоверности их медицинской информации,

обеспечение требований законодательства в части защиты персональных данных и врачебной этики.

В таком случае процесс формирования медицинского датасета рассматривается как организационно-технологическая система массового обслуживания с ограниченными ресурсами. Объектом моделирования является процесс сбора биомедицинских данных, включающий процедуры регистрации и анкетирования, антропометрические измерения, регистрацию гемодинамических показателей и проведение функциональных проб и т. п. Последовательность указанных операций формирует технологический цикл обслуживания одного пациента.

Методической основой исследования послужили методы дискретно-событийного моделирования, применяемые для анализа потоков пациентов и оптимизации организационных процессов в здравоохранении [12]. Использование аппарата теории массового обслуживания позволяет формализовать взаимосвязь между интенсивностью входящего потока пациентов и параметрами обслуживания. Коэффициент загрузки системы определяется как отношение интенсивности входящего потока λ к интенсивности обслуживания μ :

$$\rho = \frac{\lambda}{\mu}, \quad (1)$$

при этом условие устойчивости системы выполняется при $\rho < 1$.

Для каждого этапа указанного технологического цикла определялись характерные интервалы времени на основе хронометража и анализа регламентов обследования. Такой сценарный подход соответствует практике параметризации распределений времени обслуживания в исследованиях по дискретно-событийному моделированию медицинских процессов [13]. Для каждого сценария рассчитывались среднее время обслуживания одного пациента и предельная пропускная способность пункта сбора данных, определяемая как величина, обратная среднему времени цикла, приведённому к часовому интервалу.

Итоговая имитационная модель приведена на Рисунке 1.

Следующим этапом являлось моделирование входящего потока пациентов, при этом суточное количество обращений рассматривалось как стохастическая величина с вариативной интенсивностью. Анализ распределения потока пациентов позволяет оценить вероятность возникновения перегрузки системы даже при умеренном среднем значении λ , что продемонстрировано в исследованиях по моделированию массовых медицинских пунктов обслуживания [14].

В качестве исходных данных моделирования в различных сценариях задавались следующие значения интенсивности входящего потока λ , согласно треугольному распределению:

- пессимистичный сценарий (минимум 4, среднее 7, максимум 9);
- реалистичный сценарий (минимум 10, среднее 12, максимум 15);
- оптимистичный сценарий (минимум 16, среднее 19, максимум 25).

Имитационная модель реализована как цифровой двойник организационно-технологического процесса формирования медицинского датасета. Под цифровым двойником понимается динамическая вычислительная модель, воспроизводящая функционирование реальной системы на основе эмпирически полученных параметров [15]. Поскольку объектом исследования является формирование медицинского датасета, параметры моделирования сопоставлялись с требованиями к качеству и структурированию данных, предназначенных для вторичного использования в системах искусственного интеллекта [16].

Временные затраты на обслуживание одного пациента моделировались поэтапно. Для указанного примера имитационной модели расчет времени обслуживания приведен в Таблице 1.

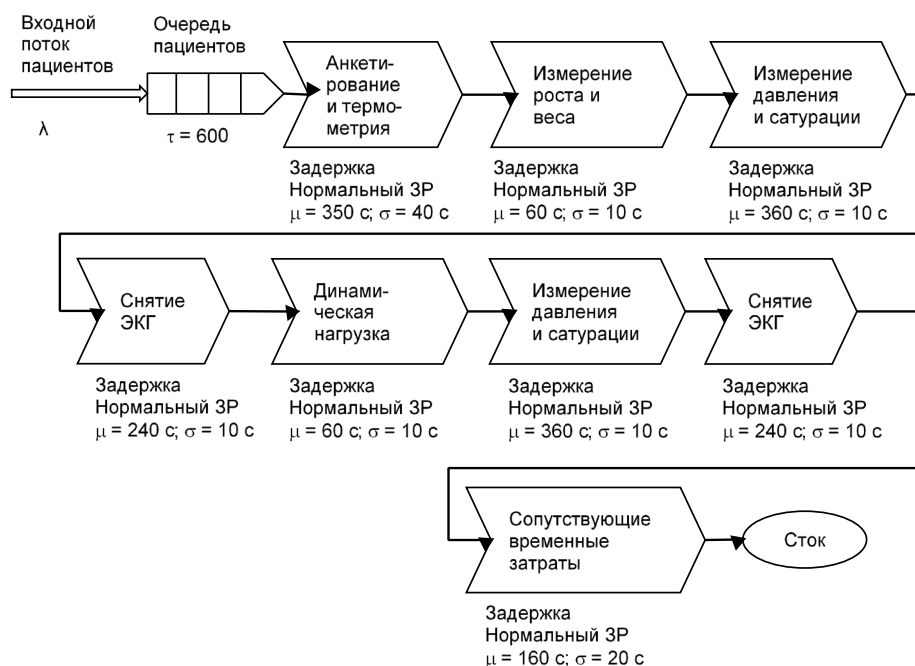


Рисунок 1 – Процесс сбора медицинских данных как система массового обслуживания

Figure 1 – The process of collecting medical data as a mass service system

Таблица 1 – Структура времени обслуживания по этапам обследования

Table 1 – Structure of service time across examination stages

№ п/п	Этап обслуживания	Среднее время, с	Доля от общего времени, %	Характеристика
1	Анкетирование и термометрия	350 ± 40	30	Ручные операции, высокая зависимость от пациента.
2	Измерение АД и Сатурации (x2)	360 ± 10	31	Технологическое время работы приборов (нагнетание манжеты).
3	Регистрация ЭКГ и Видео (x2)	240 ± 10	20	Основной целевой процесс. Высокая степень автоматизации.
4	Антропометрия (Рост/Вес)	60 ± 10	5	Вспомогательные измерения.
5	Прочие операции (нагрузка, переходы)	160 ± 20	14	Выполнение приседаний, подготовка датчиков.
Итого		1170	100	Полный цикл ~19,5 мин

Таким образом, предельная пропускная способность одной точки сбора медицинских данных определяется как

$$Z = \frac{3600}{t_{serv}}, \quad (2)$$

где t_{serv} – среднее время полного цикла обслуживания одного пациента, определяемое по данным хронометража и имитационного моделирования.

Результаты

Исследование предложенного подхода было произведено на примере анализа процессов сбора биомедицинских данных, предназначенных для обучения моделей искусственного интеллекта методам дистанционной диагностики. Эмпирическая часть исследования проводилась на базе пунктов сбора биомедицинских сигналов в течение шести месяцев. Общий объём выборки составил 574 пациента. Временные параметры этапов обслуживания определялись методом ретроспективного хронометража на основе анализа временных меток видеозаписей и логов медицинского оборудования. Полученные значения использовались для параметризации имитационной модели и формирования сценариев функционирования системы.

В рамках исследования была построена имитационная модель, позволившая провести оптимизацию процесса сбора данных. Таким образом, результаты эксперимента можно разделить на две группы: до оптимизации с использованием результатов имитационного моделирования и после нее.

На основании разработанной имитационной модели и данных ретроспективного хронометража был проведён анализ структуры времени обслуживания одного пациента. Результаты имитационного моделирования представлены на Рисунке 2. Установлено, что среднее время прохождения полного технологического цикла составляет 1170 ± 20 с ($\approx 19,5$ мин) и остаётся практически неизменным во всех сценариях функционирования системы. Различия между пессимистичным, реалистичным и оптимистичным сценариями не превышают 3 %, что свидетельствует о высокой стандартизации технологического процесса и детерминированности работы диагностического оборудования.




Рисунок 2 – Результаты имитационного моделирования
 Figure 2 – Results of simulation modeling

Структурная декомпозиция временных затрат показала, что наибольший вклад в длительность цикла вносит подготовительный блок (анкетирование и термометрия), занимающий около 30 % общего времени обслуживания. Двукратное измерение артериального давления и сатурации формирует 31 % времени цикла, тогда как непосредственная регистрация целевых сигналов (ЭКГ и видеопоток) составляет около 20 %. Таким образом, лимитирующим звеном последовательной схемы является не аппаратная регистрация биосигналов, а административная составляющая процесса.

По данным имитационного моделирования средняя интенсивность сбора данных составила 7,28 пациента в день при выраженной вариативности нагрузки.

Статистика по результатам эксперимента до и после оптимизации представлена далее на Рисунках 3 и 4. В ходе оптимизации были произведены изменения в процессе сбора данных, что позволило повысить производительность за счет распараллеливания и увеличения входящего потока пациентов.

До оптимизации процесс функционировал в режиме низкой интенсивности потока, при которой коэффициент загрузки ρ не превышал 0,2. Средняя интенсивность составила 4,67 пациентов в день. Оборудование и персонал большую часть времени находились в режиме ожидания. При этом наблюдаются дни с повышенной интенсивностью потока, что указывает на потенциальную вероятность локальной перегрузки системы даже при умеренном среднем значении.

После оптимизации наблюдается стабилизация и увеличение входящего потока. После изменения организационной схемы распределение становится более концентрированным в области средних значений, что свидетельствует о формировании устойчивого режима работы. Средняя интенсивность составила 12,12 пациентов в день при выраженной вариативности нагрузки. Однако наличие дней с пиковой посещаемостью (10 и более пациентов) указывает на неравномерность потока.

Сопоставление среднего потока пациентов с расчётной пропускной способностью показала, что при 8-часовой смене теоретический максимум последовательной модели составляет около 16 пациентов в день с учётом технологических перерывов. Фактическая средняя загрузка системы составляет порядка 45–50 % от расчётного максимума, что свидетельствует о наличии существенного резерва производственных мощностей.

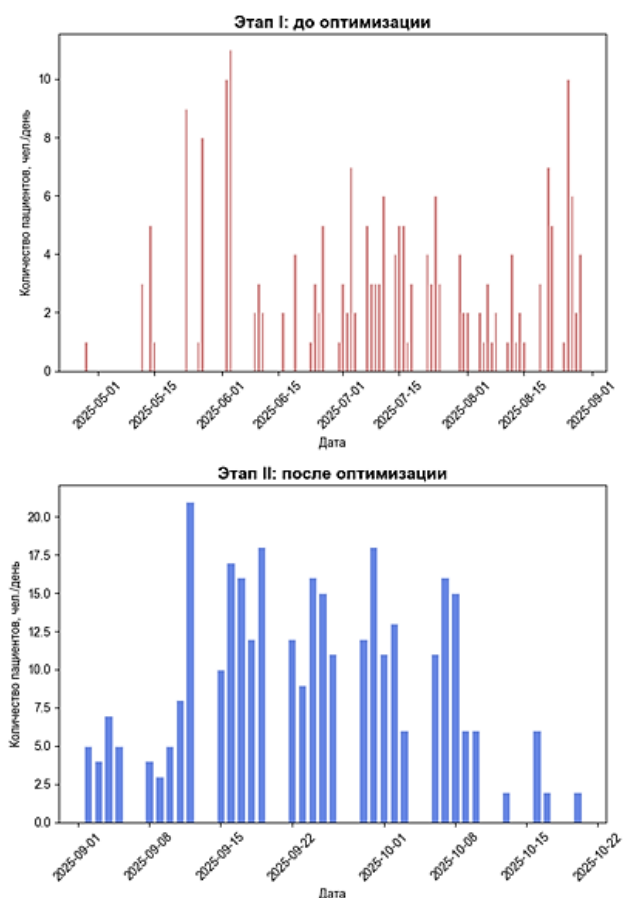


Рисунок 3 – Временные ряды потока пациентов до и после оптимизации
 Figure 3 – Time series of patient flow before and after optimization

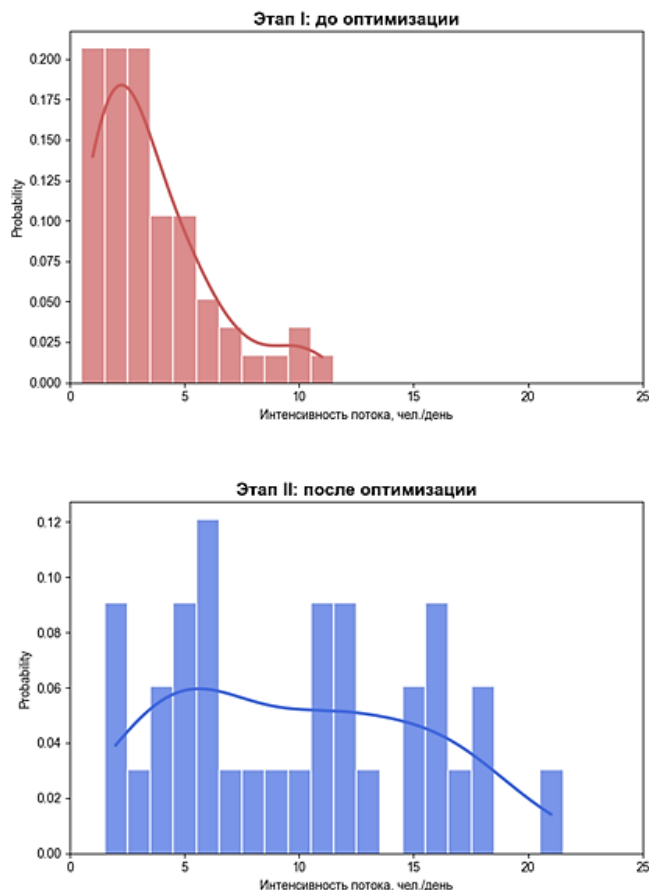


Рисунок 4 – Интенсивность приема и обслуживания пациентов до и после оптимизации
Figure 4 – Intensity of patient reception and service before and after optimization

Сценарный анализ подтвердил, что увеличение интенсивности входящего потока без изменения организационной структуры не приводит к сокращению времени обслуживания одного пациента. При сохранении последовательной архитектуры t_{serv} остаётся стабильным, а рост λ вызывает лишь увеличение очереди. Однако при обеспечении непрерывного входящего потока и вынесении этапа анкетирования за пределы критического пути обслуживания за 6 часов было обследовано 54 пациента, что соответствует фактической пропускной способности 9 пациентов в час. Таким образом, производительность увеличивается в три раза по сравнению с базовой последовательной схемой.

Итак, анализ результатов моделирования и натурных экспериментов продемонстрировал, что пропускная способность пункта сбора медицинских данных определяется не только техническими характеристиками оборудования, но и архитектурой организационного процесса, а также режимом входящего потока.

Обсуждение

Полученные результаты подтверждают, что процесс формирования медицинского датасета следует рассматривать как организационно-технологическую систему с выраженной зависимостью пропускной способности от архитектуры обслуживания. Имитационная модель показала, что при последовательной структуре технологического цикла производительность одной точки сбора определяется суммарной длительностью этапов и практически не зависит от вариаций входящего потока. Это согласуется с положениями теории массового обслуживания, согласно

которым при фиксированной интенсивности обслуживания увеличение интенсивности поступления заявок приводит прежде всего к росту очереди, а не к сокращению времени цикла.

Анализ распределения входящего потока продемонстрировал, что даже при умеренном среднем значении суточной нагрузки возможно возникновение локальных перегрузок, обусловленных стохастической природой потока. Следовательно, при планировании масштабирования проектов по сбору медицинских данных необходимо учитывать не только средние значения интенсивности, но и дисперсионные характеристики распределения.

Ключевым результатом исследования является выявление узкого места – подготовительного этапа. Вынесение анкетирования за пределы критического пути обслуживания и обеспечение насыщенного входящего потока позволили увеличить пропускную способность в три раза без изменения аппаратной конфигурации. Это свидетельствует о том, что в задачах формирования медицинских датасетов организационные решения оказывают сопоставимое, а иногда и более значимое влияние, чем модернизация оборудования.

С практической точки зрения предложенный подход позволяет проводить предварительную оценку производственных ограничений до начала масштабирования проекта. Использование имитационной модели в качестве цифрового двойника обеспечивает возможность тестирования различных сценариев функционирования без вмешательства в реальный процесс и без риска срыва сроков набора выборки. Таким образом, цифровое моделирование может служить инструментом обоснования управленческих решений при организации медицинских исследований.

Полученные результаты также демонстрируют необходимость интеграции процедур контроля качества данных с архитектурой процесса их сбора. Наличие резервной пропускной способности в штатном режиме создаёт условия для включения дополнительных процедур валидации и фильтрации без критического снижения производительности системы.

В целом исследование показывает, что формирование медицинских датасетов для задач искусственного интеллекта является не только технической, но и управленческой задачей, требующей формализованного анализа потоков, временных параметров и структуры обслуживания. Применение методов дискретно-событийного моделирования и теории массового обслуживания позволяет перейти от экспертных оценок к количественно обоснованному проектированию организационно-технологических процессов.

Заключение

В статье разработана и верифицирована имитационная модель процесса формирования медицинского датасета на основе методов дискретно-событийного моделирования и теории массового обслуживания. Показано, что при последовательной архитектуре технологического цикла среднее время обслуживания одного пациента составляет около 19,5 мин, что ограничивает пропускную способность одной точки сбора уровнем порядка 3 пациентов в час.

Анализ эмпирических данных входящего потока продемонстрировал, что при штатной эксплуатации система функционирует с существенным резервом мощности, однако стохастическая вариативность нагрузки способна приводить к локальным перегрузкам. Установлено, что лимитирующим фактором производительности является подготовительный этап, а не аппаратная регистрация биомедицинских сигналов.

Экспериментально подтверждено, что распараллеливание подпроцессов сбора данных и обеспечение насыщенного входящего потока позволяют увеличить пропускную способность с 4,67 до 12,12 пациентов в день без изменения технической конфигурации оборудования. Тем самым доказано, что организационная архитектура процесса оказывает определяющее влияние на сроки формирования медицинских датасетов.

Предложенный подход позволяет использовать имитационную модель в качестве цифрового двойника организационно-технологического процесса и применять её для предварительной оценки пропускной способности, планирования масштабирования проекта и минимизации рисков превышения календарных сроков набора выборки. Полученные результаты могут быть использованы при проектировании инфраструктуры сбора медицинских данных для систем искусственного интеллекта и при разработке регламентов функционирования исследовательских медицинских подразделений.

СПИСОК ИСТОЧНИКОВ / REFERENCES

1. Решетников Р.В., Тыров И.А., Васильев Ю.А. и др. Методики оценки качества больших генеративных моделей для базовых сценариев применения в здравоохранении. *Врач и информационные технологии*. 2025;(3):64–75. https://doi.org/10.25881/18110193_2025_3_64
Reshetnikov R.V., Tyrov I.A., Vasilev Yu.A., et al. Assessing the quality of large generative models for basic healthcare applications. *Medical Doctor and Information Technologies*. 2025;(3):64–75. (In Russ.). https://doi.org/10.25881/18110193_2025_3_64
2. Васильев Ю.А., Бобровская Т.М., Арзамасов К.М. и др. Основопологающие принципы стандартизации и систематизации информации о наборах данных для машинного обучения в медицинской диагностике. *Менеджер здравоохранения*. 2023;(4):28–41. <https://doi.org/10.21045/1811-0185-2023-4-28-41>
Vasilev Y.A., Bobrovskaya T.M., Arzamasov K.M., et al. Medical datasets for machine learning: fundamental principles of standartization and systematization. *Manager Zdravoohranenia*. 2023;(4):28–41. (In Russ.). <https://doi.org/10.21045/1811-0185-2023-4-28-41>
3. Шарова Д.Е., Михайлова А.А., Гусев А.В. и др. Анализ мирового опыта в регулировании использования медицинских данных для целей создания систем искусственного интеллекта на основе машинного обучения. *Врач и информационные технологии*. 2022;(4):28–39. https://doi.org/10.25881/18110193_2022_4_28
Sharova D.E., Mikhailova A.A., Gusev A.V., et al. An analysis of global experience in regulations on the use of medical data for artificial intelligence systems development based on machine learning. *Medical Doctor and Information Technologies*. 2022;(4):28–39. (In Russ.). https://doi.org/10.25881/18110193_2022_4_28
4. Arora A., Alderman J.E., Palmer J., et al. The value of standards for health datasets in artificial intelligence-based applications. *Nature Medicine*. 2023;29(11):2929–2938. <https://doi.org/10.1038/s41591-023-02608-w>
5. Schwabe D., Becker K., Seyferth M., Klaß A., Schaeffter T. The METRIC-framework for assessing data quality for trustworthy AI in medicine: a systematic review. *npj Digital Medicine*. 2024;7(1). <https://doi.org/10.1038/s41746-024-01196-4>
6. Kim J.-W., Kim Ch., Kim K.-H., et al. Scalable Infrastructure Supporting Reproducible Nationwide Healthcare Data Analysis toward FAIR Stewardship. *Scientific Data*. 2023;10(1). <https://doi.org/10.1038/s41597-023-02580-7>

7. Барсегян Н.В., Галимулина Ф.Ф. *Цифровое моделирование и оптимизация экономических систем: теория массового обслуживания и анализ данных*. Курск: Университетская книга; 2025. 82 с.
8. Слободняк И.А., Антипина П.В. Оптимизация организации работы сервисных служб с использованием теории управления системами массового обслуживания. *Экономика и управление: проблемы, решения*. 2020;1(12):19–24. <https://doi.org/10.36871/ek.up.p.r.2020.12.01.004>
Slobodnyak I.A., Antipina P.V. Optimize the organization of the accounting service and other service functions using the theory of management of mass service systems. *Ekonomika i upravlenie: problemy, resheniya*. 2020;1(12):19–24. (In Russ.). <https://doi.org/10.36871/ek.up.p.r.2020.12.01.004>
9. Полухин П.В. Применение методов теории массового обслуживания для оценки параметров синхронизации распределенных вычислительных систем. *Моделирование, оптимизация и информационные технологии*. 2022;10(2). <https://doi.org/10.26102/2310-6018/2022.37.2.028>
Polukhin P.V. Application of queueing theory methods for estimating synchronization parameters of distributed computing systems. *Modeling, Optimization and Information Technology*. 2022;10(2). (In Russ.). <https://doi.org/10.26102/2310-6018/2022.37.2.028>
10. Третьякова М.Е., Смакуев А.Д., Филатов В.В. Проектирование процесса оказания услуг на основе методов теории массового обслуживания. *Прикладные экономические исследования*. 2022;(2):24–31. https://doi.org/10.47576/2313-2086_2022_2_24
Tretyakova M.E., Smakuev A.J., Filatov V.V. Designing the process of providing services based on the methods of the theory of queuing. *Applied economic research*. 2022;(2):24–31. (In Russ.). https://doi.org/10.47576/2313-2086_2022_2_24
11. Touré V., Krauss Ph., Gnodtke K., et al. FAIRification of health-related data using semantic web technologies in the Swiss Personalized Health Network. *Scientific Data*. 2023;10. <https://doi.org/10.1038/s41597-023-02028-y>
12. Fun W.H., Tan E.H., Khalid R., et al. Applying Discrete Event Simulation to Reduce Patient Wait Times and Crowding: The Case of a Specialist Outpatient Clinic with Dual Practice System. *Healthcare*. 2022;10(2). <https://doi.org/10.3390/healthcare10020189>
13. Vecillas Martín D., Berruezo Fernández Ch., Gento Municio A.M. Systematic Review of Discrete Event Simulation in Healthcare and Statistics Distributions. *Applied Sciences*. 2025;15(4). <https://doi.org/10.3390/app15041861>
14. Di Pumpo M., Ianni A., Miccoli G.A., et al. Queueing Theory and COVID-19 Prevention: Model Proposal to Maximize Safety and Performance of Vaccination Sites. *Frontiers in Public Health*. 2022;10. <https://doi.org/10.3389/fpubh.2022.840677>
15. Kuruppu Appuhamilage G.D.K., Hussain M., Zaman M., Khan W.A. A health digital twin framework for discrete event simulation based optimised critical care workflows. *npj Digital Medicine*. 2025;8(1). <https://doi.org/10.1038/s41746-025-01738-4>
16. Declerck J., Kalra D., Vander Stichele R., Coorevits P. Frameworks, Dimensions, Definitions of Aspects, and Assessment Methods for the Appraisal of Quality of Health Data for Secondary Use: Comprehensive Overview of Reviews. *JMIR Medical Informatics*. 2024;12. <https://doi.org/10.2196/51560>

ИНФОРМАЦИЯ ОБ АВТОРАХ / INFORMATION ABOUT THE AUTHORS

Иващенко Антон Владимирович, доктор технических наук, профессор, директор Передовой медицинской инженерной школы, Самарский государственный медицинский университет, Самара, Российская Федерация.
e-mail: anton.ivashenko@gmail.com
ORCID: [0000-0001-7766-3011](https://orcid.org/0000-0001-7766-3011)

Anton V. Ivaschenko, Doctor of Engineering Sciences, Professor, Director of the Higher School of Medical Engineering, Samara State Medical University, Samara, the Russian Federation.

Терехин Михаил Александрович, ассистент Передовой медицинской инженерной школы, Самарский государственный медицинский университет, Самара, Российская Федерация.
e-mail: terexin.m.a@yandex.ru
ORCID: [0009-0004-1127-0978](https://orcid.org/0009-0004-1127-0978)

Mikhail A. Terekhin, Assistant of the Higher School of Medical Engineering, Samara State Medical University, Samara, the Russian Federation.

Порецкова Галина Юрьевна, доктор медицинских наук, доцент, заведующий кафедрой факультетской педиатрии, Самарский государственный медицинский университет, Самара, Российская Федерация.
e-mail: g.yu.poreckova@samsmu.ru
ORCID: [0000-0002-3131-1368](https://orcid.org/0000-0002-3131-1368)

Galina Yu. Poretskova, Doctor of Medical Sciences, Docent, Head of the Department of Faculty Pediatrics, Samara State Medical University, Samara, the Russian Federation.

Жданович Герман Эдуардович, аспирант Приволжского государственного университета путей сообщения, Самара, Российская Федерация.
e-mail: german-zhdanovich@yandex.ru
ORCID: [0009-0001-4497-4216](https://orcid.org/0009-0001-4497-4216)

German E. Zhdanovich, Postgraduate, Volga State Transport University, Samara, the Russian Federation.

Мельников Денис Алексеевич, аспирант Пензенского государственного технологического университета, Пенза, Российская Федерация.
e-mail: den.melnickov2001@yandex.ru
ORCID: [0009-0005-8611-0204](https://orcid.org/0009-0005-8611-0204)

Denis A. Melnikov, Postgraduate, Penza State Technological University, Penza, the Russian Federation.

Радаев Дмитрий Евгеньевич, аспирант Пензенского государственного технологического университета, Пенза, Российская Федерация.
e-mail: khierobin@mail.ru
ORCID: [0009-0005-5291-1791](https://orcid.org/0009-0005-5291-1791)

Dmitry E. Radaev, Postgraduate, Penza State Technological University, Penza, the Russian Federation.

Статья поступила в редакцию 16.02.2026; одобрена после рецензирования 14.04.2026; принята к публикации 21.04.2025.

The article was submitted 16.02.2026; approved after reviewing 14.04.2026; accepted for publication 21.04.2026.