

© CC BY Коллектив авторов, 2025
 УДК 616-056.52-089-06-036.8.004.8
<https://doi.org/10.24884/0042-4625-2025-184-5-36-43>

ПРОГНОЗИРОВАНИЕ ОСЛОЖНЕНИЙ ПОСЛЕ БАРИАТРИЧЕСКОЙ ХИРУРГИИ С ИСПОЛЬЗОВАНИЕМ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

А. Г. Хитарьян^{1, 2}, А. В. Межунц^{1, 2*}, К. С. Велиев², А. А. Орехов^{1, 2}, Д. А. Мельников^{1, 2},
О. С. Пен^{1, 2}, Д. Ю. Пуковский², А. Г. Османян¹, З. И. Потокова¹, А. С. Гаспарян¹

¹ Ростовский государственный медицинский университет
 344022, Россия, г. Ростов-на-Дону, Нахичеванский пер., д. 29

² Клиническая больница «РЖД-Медицина»
 344011, Россия, г. Ростов-на-Дону, ул. Варфоломеева, д. 92а

Поступила в редакцию 26.05.2025 г.; принята к печати 01.10.2025 г.

ЦЕЛЬ. Разработка, валидация и программная реализация клиничко-лабораторной модели на основе машинного обучения (ML) для раннего выявления и своевременной профилактики послеоперационных осложнений у пациентов, перенесших бариатрические вмешательства.

МЕТОДЫ И МАТЕРИАЛЫ. Выполнен ретроспективный анализ клинических данных 2011 пациентов, перенесших бариатрическую операцию. В исследование были включены демографические параметры, клинические симптомы, лабораторные показатели, данные визуализации, а также сведения о течении послеоперационного периода. Построена модель логистической регрессии с применением автоматического взвешивания классов, что позволило скорректировать дисбаланс классов и повысить точность предсказаний. Эффективность модели оценивалась по основным метрикам: AUC, точность, чувствительность, специфичность и F1-score.

РЕЗУЛЬТАТЫ. Разработанная модель продемонстрировала высокую прогностическую точность (AUC=0,975, точность 94,8 %, чувствительность 93,1 %). Наиболее значимыми признаками для классификации осложнений оказались уровни С-реактивного белка, тахикардия, лихорадка, выраженность симптомов и лабораторные маркеры воспаления.

ЗАКЛЮЧЕНИЕ. Представленная модель машинного обучения имеет высокий потенциал для интеграции в клиническую практику и может стать основой для создания интеллектуальных систем раннего предупреждения осложнений, автоматизированного мониторинга и поддержки принятия врачебных решений.

Ключевые слова: бариатрическая хирургия, послеоперационные осложнения, машинное обучение, искусственный интеллект, прогностическая модель

Для цитирования: Хитарьян А. Г., Межунц А. В., Велиев К. С., Орехов А. А., Мельников Д. А., Пен О. С., Пуковский Д. Ю., Османян А. Г., Потокова З. И., Гаспарян А. С. Прогнозирование осложнений после бариатрической хирургии с использованием искусственного интеллекта. *Вестник хирургии имени И. И. Грекова*. 2025;184(5):36–43. <https://doi.org/10.24884/0042-4625-2025-184-5-36-43>.

* **Автор для связи:** Арут Ваграмович Межунц, Клиническая больница «РЖД-Медицина», 344011, Россия, г. Ростов-на-Дону, ул. Варфоломеева, д. 92а. E-mail: arut.mezhunts@mail.ru.

PREDICTION OF POSTOPERATIVE COMPLICATIONS IN PATIENTS AFTER BARIATRIC SURGERY WITH USING THE ARTIFICIAL INTELLIGENCE

Alexander G. Khitaryan^{1, 2}, Arut V. Mezhunts^{1, 2*}, Kamil S. Veliev², Alexey A. Orekhov^{1, 2},
Denis A. Melnikov^{1, 2}, Oleg S. Pen^{1, 2}, Denis Yu. Pukovsky², Ani G. Osmanian¹,
Zarina I. Potokova¹, Arman S. Gasparian¹

¹ Rostov State Medical University
 9, Nakhichevansky str., Rostov-on-Don, Russia, 344022

² Clinical Hospital «RZD-Medicine»
 92a, Varfolomeeva str., Rostov-on-Don, Russia, 344011

Received 26.05.2025; accepted 01.10.2025

The OBJECTIVE was to develop, validate, and implement a clinical and laboratory model based on machine learning (ML) for the early identification and timely prevention of postoperative complications in patients who have undergone bariatric surgery.

METHODS AND MATERIALS. A retrospective analysis was performed on clinical data from 2,011 patients who underwent bariatric procedures. The study included demographic characteristics, clinical symptoms, laboratory findings, imaging results, and details of the postoperative course. A logistic regression model was constructed using automatic class weighting to correct for class imbalance and improve predictive accuracy. The model's performance was evaluated using key metrics: AUC, accuracy, sensitivity, specificity, and F1-score.

RESULTS. The developed model demonstrated high predictive performance (AUC=0.975, accuracy=94.8 %, sensitivity=93.1 %). The most significant predictors of postoperative complications were elevated C-reactive protein levels, tachycardia, fever, symptom severity, and inflammatory laboratory markers.

CONCLUSION. The proposed machine learning model shows substantial potential for integration into clinical practice and may serve as a foundation for developing intelligent systems for early complication warning, automated monitoring, and clinical decision support.

Keywords: *bariatric surgery, postoperative complications, machine learning, artificial intelligence, predictive model*

For citation: Khitaryan A. G., Mezherits A. V., Veliev K. S., Orekhov A. A., Melnikov D. A., Pen O. S., Pukovsky D. Yu., Osmanian A. G., Potokova Z. I., Gasparian A. S. Prediction of postoperative complications in patients after bariatric surgery with using the artificial intelligence. *Grekov's Bulletin of Surgery*. 2025;184(5):36–43. (In Russ.). <https://doi.org/10.24884/0042-4625-2025-184-5-36-43>.

* **Corresponding author:** Arut V. Mezherits, Clinical Hospital «RZD-Medicine», 92a, Varfolomeeva str., Rostov-on-Don, 344011, Russia. E-mail: arut.mezherits@mail.ru.

Введение. Осложнения после бариатрической хирургии остаются актуальной клинической проблемой. Несмотря на развитие хирургических техник и протоколов Enhanced Recovery After Surgery (ERAS), риск осложнений сохраняется и может приводить к пролонгированной госпитализации, повторным операциям и увеличению затрат. Традиционные шкалы оценки риска, такие как POSSUM и OS-MRS, имеют ограниченную точность. Современные методы машинного обучения (ML) позволяют учитывать большое количество признаков и выявлять сложные закономерности в данных. Наиболее перспективными являются модели, основанные на данных, получаемых в течение первых суток после операции, что позволяет использовать их в клинической практике для своевременного реагирования [1, 2].

Целью настоящего исследования стала разработка, валидация и программная реализация клинико-лабораторной модели машинного обучения для раннего прогнозирования послеоперационных осложнений у пациентов, перенесших бариатрические вмешательства.

Методы и материалы. 1. *Дизайн исследования.* В исследование были включены данные 2011 пациентов, перенесших бариатрическую операцию в специализированном хирургическом центре. Критерии включения: возраст старше 18 лет, наличие полной информации о клинико-лабораторных параметрах в первые 1–3 дня после операции. Исключались пациенты с неполными данными и повторными вмешательствами в течение основного периода наблюдения. В качестве предикторов использовались послеоперационные признаки: жалобы (рвота, боль), температура тела, частота сердечных сокращений, лабораторные показатели (лейкоциты, гемоглобин, СРБ, D-димер), визуализационные исследования, объем отделяемого по дренажу. Целевой переменной являлось наличие клинически значимого осложнения (в том

числе несостоятельность линии степлерного шва и/или анастомоза) в течение первых 24–48 часов.

2. *Первичный анализ.* С целью первичного отбора предикторов был выполнен односторонний ROC-анализ по каждому параметру с расчетом AUC и индекса Юдена (Youden Index). Для включения в модель рассматривались признаки с $AUC \geq 0,7$. Установлены следующие клинически значимые пороги:

- ВАШ > 4 баллов;
- дренаж ≥ 70 мл/сутки;
- ЧСС > 100 уд./мин;
- лейкоциты > 14×10^9 /л;
- палочкоядерные нейтрофилы > 9 %;
- СРБ $\geq 129,5$ мг/л;
- лихорадка > 38 °C.

Бинарная целевая переменная: наличие/отсутствие осложнения, подтвержденное клинически и/или оперативно.

Перед построением модели был проведен анализ чувствительности и специфичности каждого непрерывного предиктора с помощью ROC-кривых (Receiver Operating Characteristic). Это позволило:

- оценить AUC каждого признака (отражает прогностическую силу);
- установить оптимальные пороговые значения с максимальной диагностической эффективностью (по критерию Youden).

Результаты приведены в *табл. 1*.

3. *Создание и обучение модели машинного обучения.*

3.1. *Выбор алгоритма и предобработка данных.* В качестве алгоритма была выбрана логистическая регрессия как метод, обладающий высокой интерпретируемостью, устойчивостью к мультиколлинеарности и возможностью прямой клинической верификации результатов. Все переменные были нормированы и закодированы:

- бинарные предикторы: преобразованы через пороги ROC-анализа;

Таблица 1

Оптимальные пороговые значения каждого признака

Table 1

Optimal threshold values for each feature

Параметр	AUC	Порог	Se	Sp
СРБ, мг/л	0,84	>129,5	83,3 %	75,2 %
Лейкоциты, $\times 10^9/\text{л}$	0,79	>14,0	82,1 %	71,4 %
Палочкоядерные нейтрофилы	0,81	>9 % (через 36 часов)	55,6 %	72,1 %
ВАШ	0,77	>4 баллов	75,0 %	66,0 %
ЧСС	0,70	>100 уд/мин	63,4 %	68,1 %
Лихорадка, °C	0,72	≥ 38 °C	67,2 %	69,0 %
Объем дренажа	0,91	≥ 70 мл/сутки	94,2 %	86,1 %

Таблица 2

Оценка точности модели

Table 2

Model performance evaluation

Метрика	Значение
Accuracy (точность)	94,8 %
Sensitivity (чувствительность)	93,1 %
Specificity (специфичность)	91,3 %
AUC (общая прогностическая способность)	0,975




Рис. 1. ROC-кривая

Fig. 1. ROC-curve

– численные предикторы: центрированы (mean normalization).

Модель логистической регрессии обучалась на 80 % выборки (тренировочный набор), остальные 20 % использовались для валидации. Модель обучалась по схеме supervised-learning с бинарной меткой 1 – наличие осложнения в течение 24–48 часов. Обучение проводилось с помощью библиотеки Scikit-learn (Python). Для борьбы с дисбалансом

классов применен SMOTE (Synthetic Minority Over-sampling Technique), увеличивающий представительство группы с осложнениями путем синтетической генерации наблюдений:

- пропущенные значения были обработаны методом медианного заполнения;
- дисбаланс классов устранен методом SMOTE (Synthetic Minority Over-sampling Technique);
- все количественные переменные нормированы (z-score).

Затем проводили оценку точности модели, результаты приведены в табл. 2.

3.2. Итоговая формула логистической модели. На основании значимых коэффициентов была сформирована следующая модель:

$$\begin{aligned}
 &r = -2,86 \\
 &+ 1,687 \times \text{ВАШ} \\
 &+ 3,146 \times \text{Drain_70} \\
 &+ 0,167 \times \text{Neutro} \\
 &+ 0,05 \times \text{Tachy (ЧСС > 100)} \\
 &+ 0,07 \times \text{Leukocytosis (WBC > } 14 \times 10^9/\text{л)} \\
 &+ 0,05 \times \text{CRP (CRP > 129,5 мг/л)}
 \end{aligned}$$

Температура > 38,0 °C → клинически значимая интеграция

Риск осложнения интерпретируется как:

$$P(\text{Осложнение}) = 1 / (1 + e^{(-r)}).$$

Пороговое значение $\geq 0,08$ – индикатор высокого риска (Se=93,1 %, Sp=91,3 %, AUC=0,975) – соответствовало максимальному значению индекса Youden и использовалось как триггер для клинических решений (усиление наблюдения, КТ, релапароскопия). Визуализация данных представлена на рис. 1, 2.

На рис. 1 представлена ROC-кривая итоговой модели, AUC составила 0,975. Это свидетельствует о высокой прогностической способности модели.

На рис. 2 представлена логистическая функция вероятности развития осложнений. Красной пунктирной линией обозначено пороговое значение $r=0,08$, при котором начинается высокая зона риска.

4. Программная реализация. Для практической имплементации модели в клиническую среду была создана веб-ориентированная система, позволяющая реализовать визуальный интерактивный интерфейс для врачей с возможностью расчета логистической модели.

Функциональность приложения включает:

- форму ввода значений клинико-лабораторных параметров;
- автоматический расчет логистической регрессии по формуле;
- визуализацию положения пациента на графике логистической функции;
- цветовую индикацию степени риска (□ – низкий, • – высокий);
- модульную структуру с возможностью расширения.

Результаты. Всего за 8-летний период исследования было выполнено 2011 бариатрических операций, включающих основные методы оперативного лечения, применяемые в центре бариатрической и метаболической хирургии ЧУЗ «КБ «РЖД-Медицина» г. Ростов-на-Дону». Лапароскопическая продольная резекция желудка была выполнена 1360 пациентам (67,4 %); гастрощунтирование по Ру выполнялось 446 пациенту (22,2 %); гастрощунтирование с одним анастомозом (МГШ) – 187 пациентам (9,5 %). В 18 (0,9 %) случаях были выполнены иные операции, такие как лапароскопическая продольная резекция с анастомозом (операция SASI или Transit Bipartition), или операция SADI. Из структуры общей группы пациентов были выделены те пациенты, у которых были выявлены воспалительные интраабдоминальные осложнения – 28 больных. Средний вес у пациентов с осложнениями вне зависимости от типа осложнения составил $127,2 \pm 26,7$ кг. Средний ИМТ у пациентов с осложнениями был равен $45,2 \pm 10,2$ кг/м²; средний возраст составил $48,6 \pm 9,7$ лет. Таким образом, с 2016 по 2023 гг. в 28 случаях были выявлены те или иные воспалительные интраабдоминальные осложнения, потребовавшие выполнения ранней релапароскопии. Общая частота послеоперационных осложнений составила 1,39 %: несостоятельность линии степлерного шва была выявлена в 14 случаях (встречалась только при ЛПРЖ); в 6 случаях после МГШ была выявлена несостоятельность гастроэнтероанастомоза; при РуГШ несостоятельность гастроэнтероанастомоза была у 1 пациента, вследствие тяжести состояния пациента было принято решение о выполнении лапаротомии, несостоятель-




Рис. 2. Логистическая функция

Fig. 2. Logistic function

ность энтероэнтероанастомоза – 3 случая; также было выявлено 4 случая стеноза энтероэнтероанастомоза с развитием непроходимости билиарной петли тонкой кишки после РуГШ. Основными клинико-лабораторными маркерами являлись: жалобы (рвота, боль), температура тела, частота сердечных сокращений, лабораторные показатели (лейкоциты, гемоглобин, СРБ, D-димер), визуализационные исследования, объем отделяемого по дренажу. После предобработки данных и исключения переменных с высокой долей пропусков была обучена модель логистической регрессии на послеоперационных признаках. Результаты тестирования модели на валидационной выборке показали следующие показатели: точность – 94,8 %, чувствительность – 93,1 %, специфичность – 91,3 %, F1-метрика – 0,95, AUC – 0,975. Наиболее значимыми признаками в модели оказались: болевой синдром по ВАШ, повышение уровня СРБ, температура тела, лейкоцитоз и нейтрофильный сдвиг, а также суточное отделяемое по дренажам из брюшной полости. Построенная модель позволила эффективно выделить группу пациентов с высоким риском осложнений в ранние сроки после операции.

Для упрощения применения предиктивных моделей в клинической практике была разработана графическая пользовательская оболочка (рис. 3–4). Интерфейс позволяет выбрать набор входных данных и выдает соответствующую вероятность развития послеоперационных осложнений.

Обсуждение. Полученные результаты демонстрируют высокую точность прогнозирования послеоперационных осложнений с использованием модели машинного обучения на основе доступных клинических параметров. В отличие от традиционных шкал, представленный алгоритм позволяет учитывать индивидуальные особенности течения послеоперационного периода. Высокая чувствительность и AUC модели позволяют рассматривать ее как потенциальный инструмент


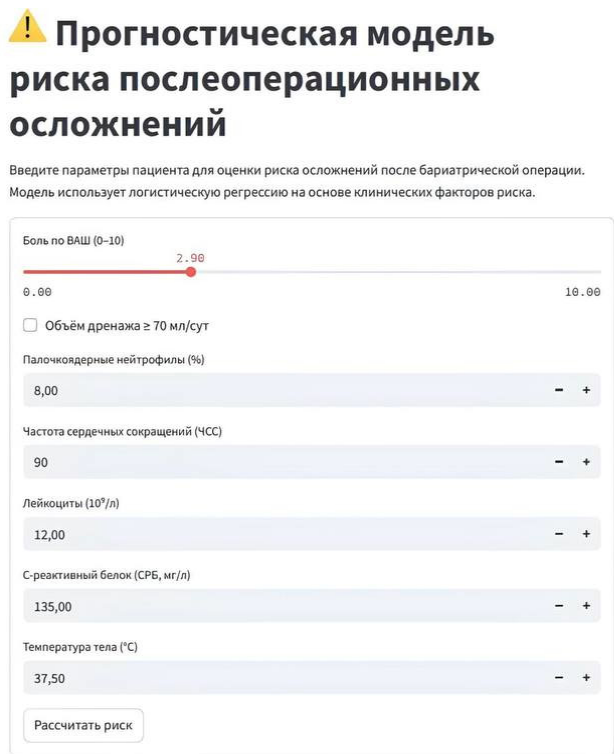


Рис. 3. Пример графического интерфейса программы с низким риском развития осложнений
Fig. 3. The example of the program's graphical interface showing low risk of complications


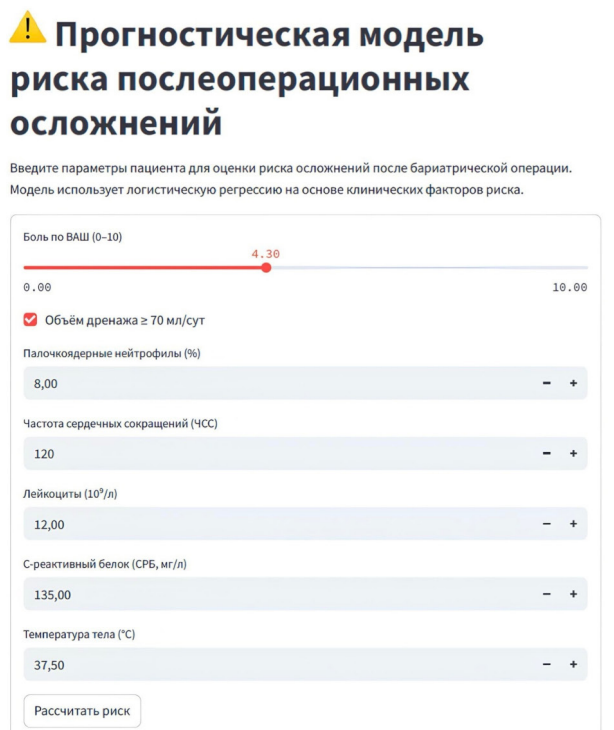


Рис. 4. Пример графического интерфейса программы с высоким риском развития осложнений
Fig. 4. The example of the program's graphical interface showing high risk of complications

раннего предупреждения и принятия клинических решений. Сильной стороной исследования является использование рутинных данных, доступных в стандартной клинической практике, что обеспечивает реалистичность и потенциальную масштабируемость модели. Ограничениями являются

ретроспективный дизайн, одномоментное использование данных одного центра и необходимость внешней валидации на независимой выборке. Также возможны искажения, связанные с неполнотой саморегистрации симптомов пациентами. Несмотря на указанные ограничения, достигнутые

показатели сопоставимы с результатами других ИИ-моделей, применяемых в хирургии. Например, в абдоминальной хирургии значения AUC при использовании ML-моделей варьировали от 57 до 95 %, что подчеркивает высокую вариабельность и потенциальную конкурентоспособность нашего подхода [8, 9].

Осложнения после бариатрической хирургии могут развиваться на любом этапе послеоперационного периода. В ретроспективном исследовании A. S. Mierzwa et al. (2021) [10], охватившем 316 314 пациентов из базы данных Metabolic and Bariatric Surgery Accreditation and Quality Improvement Program (MBSAQIP), было показано, что значительная часть септических осложнений возникает позже второй недели послеоперационного периода, когда пациенты уже выписаны из стационара. Поскольку этот временной отрезок характеризуется ограниченным медицинским наблюдением, внедрение дистанционного мониторинга с помощью мобильного приложения может повысить чувствительность к отклонениям от нормального послеоперационного течения [3]. Дополнительно такие данные могут быть интегрированы в модель машинного обучения для более точной стратификации риска. Таким образом, мобильное наблюдение не только усиливает клинический контроль, но и способствует персонализированной адаптации лечения на амбулаторном этапе. Построенная нами послеоперационная модель продемонстрировала высокую устойчивость и точность, достигнув 94,8 точности и 93,1 % чувствительности. Это подчеркивает ценность включения динамических данных мониторинга в клиническую практику. Подобная модель имеет явные клинические преимущества, так как обеспечивает непрерывное, ориентированное на пациента наблюдение, позволяющее врачам переоценивать риск осложнений на протяжении всего послеоперационного периода. Это особенно важно в бариатрической хирургии, где осложнения могут развиваться отсроченно и требуют раннего выявления для предотвращения их прогрессирования. Послеоперационные осложнения могут оказывать существенное влияние на состояние и прогноз пациента, особенно такие, как кровотечения, несостоятельность анастомоза и тромбозы, которые ассоциированы с повышенной летальностью и необходимостью госпитализации в ОРИТ или проведения повторных операций. Более того, они могут вызывать длительное снижение качества жизни, особенно при несвоевременном или недостаточном лечении. Даже незначительные осложнения могут иметь клиническое значение: бариатрические пациенты предрасположены к тошноте и рвоте [12], что ограничивает гидратацию и может привести к продлению госпитализации или повторной госпитализации [13]. Также временная дисфагия (не

связанная с механическим препятствием, таким как перегиб или стриктура) способна ухудшить питательный и водный статус пациента. Активное наблюдение и своевременное вмешательство при таких симптомах позволяют улучшить восстановление. Настоящее исследование имеет ряд существенных ограничений. Прежде всего, ретроспективный дизайн, одномоментное использование данных одного центра и необходимость внешней валидации на независимой выборке. Расширение исследования за счет многоцентровых данных повысит устойчивость модели и позволит провести внешнюю валидацию.

Кроме того, данные, собранные в рамках одного учреждения, клинические характеристики пациентов, а также особенности ведения послеоперационного периода могут не отражать практику других клиник. Еще одним фактором, способным повлиять на точность модели, является смещение, связанное с саморегистрацией данных пациентом, включая недооценку или неверное истолкование симптомов. Для подтверждения универсальности модели необходима ее валидация на других популяциях пациентов, перенесших бариатрические вмешательства.

Еще один важный момент – это дисбаланс классов в выборке, из-за чего понадобилось использовать алгоритм SMOTE. Хотя он способствует улучшению обучения модели путем синтетического увеличения числа редких событий, он также может создавать неполноценные или упрощенные паттерны, не отражающие реальную клиническую вариативность. Наконец, текущая модель дает общую оценку риска послеоперационных осложнений, не дифференцируя их по типу или степени тяжести. В будущем следует стремиться к более детализированной классификации, что повысит клиническую ценность модели и позволит формировать персонализированные протоколы лечения. Несмотря на указанные ограничения, исследование демонстрирует потенциал интеграции искусственного интеллекта и мобильных технологий для улучшения прогнозирования послеоперационного риска. Дальнейшая валидация на больших и более разнообразных выборках будет необходима для полноценной реализации клинических преимуществ такого подхода.

Выводы. 1. Модель логистической регрессии, обученная на послеоперационных клинических и лабораторных параметрах, показала высокую точность в прогнозировании осложнений у пациентов после бариатрической хирургии.

2. Интеграция такой модели в клиническую практику может способствовать ранней диагностике и снижению частоты тяжелых осложнений.

3. Необходимы дальнейшие исследования с внешней валидацией для подтверждения обобщаемости модели и оценки ее влияния на клинические исходы.

Конфликт интересов

Авторы заявили об отсутствии конфликта интересов.

Conflict of interest

The authors declare no conflict of interest.

Соответствие нормам этики

Авторы подтверждают, что соблюдены права людей, принимавших участие в исследовании, включая получение информированного согласия в тех случаях, когда оно необходимо, и правила обращения с животными в случаях их использования в работе. Подробная информация содержится в Правилах для авторов.

Compliance with ethical principles

The authors confirm that they respect the rights of the people participated in the study, including obtaining informed consent when it is necessary, and the rules of treatment of animals when they are used in the study. Author Guidelines contains the detailed information.

ЛИТЕРАТУРА

1. Sheikhtaheri A., Orooji A., Pazouki A. et al. A Clinical decision support system for predicting the early complications of one-anastomosis gastric bypass surgery. *Obes Surg.* 2019. Vol. 29. P. 2276–86. <https://doi.org/10.1007/s11695-019-03849-w>.
2. Cao Y., Fang X., Ottosson J. et al. A comparative study of machine learning algorithms in predicting severe complications after bariatric surgery. *J Clin Med.* 2019. Vol. 8. P. 668. <https://doi.org/10.3390/jcm8050668>.
3. Yang C., Kessler M., Taebi N. et al. Remote follow-up with a mobile application is equal to traditional outpatient follow-up after bariatric surgery: the BELLA pilot trial. *Obes Surg.* 2023. Vol. 33. P. 1702–9. <https://doi.org/10.1007/s11695-023-06587-2>.
4. Lopez-Arevalo I., Aldana-Bobadilla E., Molina-Villegas A. et al. A memory-efficient encoding method for processing mixed-type data on machine learning. *Entropy (Basel).* 2020. Vol. 22. P. 1391. <https://doi.org/10.3390/e22121391>.
5. Wang S., Dai Y., Shen J. et al. Research on expansion and classification of imbalanced data based on SMOTE algorithm. *Sci Rep.* 2021. Vol. 11. P. 24039. <https://doi.org/10.1038/s41598-021-03430-5>.
6. Razzaghi T., Safo I., Ewing J. et al. Predictive models for bariatric surgery risks with imbalanced medical datasets. *Ann Oper Res.* 2019. Vol. 280. P. 1–18. <https://doi.org/10.1007/s10479-019-03156-8>.
7. Migenda N., Möller R., Schenck W. Adaptive dimensionality reduction for neural network-based online principal component analysis. *PLoS ONE.* 2021. Vol. 16. P. e0248896. <https://doi.org/10.1371/journal.pone.0248896>.
8. Hassan A. M., Rajesh A., Asaad M. et al. Artificial intelligence and machine learning in prediction of surgical complications: current state, applications, and implications. *Am Surg.* 2023. Vol. 89. P. 25–30. <https://doi.org/10.1177/00031348221101488>.
9. Stam W. T., Goedknecht L. K., Ingwersen E. W. et al. The prediction of surgical complications using artificial intelligence in patients undergoing major abdominal surgery: a systematic review. *Surgery.* 2022. Vol. 171. P. 1014–21. <https://doi.org/10.1016/j.surg.2021.10.002>.
10. Mierzwa A. S., Mocanu V., Marcil G. et al. Characterizing timing of postoperative complications following elective Roux-en-Y gastric bypass and sleeve gastrectomy. *Obes Surg.* 2021. Vol. 31. P. 4492–501. <https://doi.org/10.1007/s11695-021-05638-w>.

11. Zucchini N., Capozzella E., Giuffrè M. et al. Advanced non-linear modeling and explainable artificial intelligence techniques for predicting 30-day complications in bariatric surgery: a single-center study. *OBES SURG.* 2024. Vol. 34. P. 3627–38. <https://doi.org/10.1007/s11695-024-07501-0>.
12. Groene P., Eisenlohr J., Zeuzem C. et al. Postoperative nausea and vomiting in bariatric surgery in comparison to non-bariatric gastric surgery. *Wideochir Inne Tech Maloinwazyjne.* 2019. Vol. 14. P. 90–5. <https://doi.org/10.5114/wiitm.2018.77629>.
13. Suh S., Helm M., Kindel T. L. et al. The impact of nausea on post-operative outcomes in bariatric surgery patients. *Surg Endosc.* 2020. Vol. 34. P. 3085–91. <https://doi.org/10.1007/s00464-019-07058-5>.

REFERENCES

1. Sheikhtaheri A., Orooji A., Pazouki A. et al. A Clinical decision support system for predicting the early complications of one-anastomosis gastric bypass surgery. *Obes Surg.* 2019;29:2276–86. <https://doi.org/10.1007/s11695-019-03849-w>.
2. Cao Y., Fang X., Ottosson J. et al. A comparative study of machine learning algorithms in predicting severe complications after bariatric surgery. *J Clin Med.* 2019;8:668. <https://doi.org/10.3390/jcm8050668>.
3. Yang C., Kessler M., Taebi N. et al. Remote follow-up with a mobile application is equal to traditional outpatient follow-up after bariatric surgery: the BELLA pilot trial. *Obes Surg.* 2023;33:1702–9. <https://doi.org/10.1007/s11695-023-06587-2>.
4. Lopez-Arevalo I., Aldana-Bobadilla E., Molina-Villegas A. et al. A memory-efficient encoding method for processing mixed-type data on machine learning. *Entropy (Basel).* 2020;22:1391. <https://doi.org/10.3390/e22121391>.
5. Wang S., Dai Y., Shen J. et al. Research on expansion and classification of imbalanced data based on SMOTE algorithm. *Sci Rep.* 2021;11:24039. <https://doi.org/10.1038/s41598-021-03430-5>.
6. Razzaghi T., Safo I., Ewing J. et al. Predictive models for bariatric surgery risks with imbalanced medical datasets. *Ann Oper Res.* 2019;280:1–18. <https://doi.org/10.1007/s10479-019-03156-8>.
7. Migenda N., Möller R., Schenck W. Adaptive dimensionality reduction for neural network-based online principal component analysis. *PLoS ONE.* 2021;16:e0248896. <https://doi.org/10.1371/journal.pone.0248896>.
8. Hassan A. M., Rajesh A., Asaad M. et al. Artificial intelligence and machine learning in prediction of surgical complications: current state, applications, and implications. *Am Surg.* 2023;89:25–30. <https://doi.org/10.1177/00031348221101488>.
9. Stam W. T., Goedknecht L. K., Ingwersen E. W. et al. The prediction of surgical complications using artificial intelligence in patients undergoing major abdominal surgery: a systematic review. *Surgery.* 2022;171:1014–21. <https://doi.org/10.1016/j.surg.2021.10.002>.
10. Mierzwa A. S., Mocanu V., Marcil G. et al. Characterizing timing of postoperative complications following elective Roux-en-Y gastric bypass and sleeve gastrectomy. *Obes Surg.* 2021;31:4492–501. <https://doi.org/10.1007/s11695-021-05638-w>.
11. Zucchini N., Capozzella E., Giuffrè M. et al. Advanced non-linear modeling and explainable artificial intelligence techniques for predicting 30-day complications in bariatric surgery: a single-center study. *OBES SURG.* 2024;34:3627–38. <https://doi.org/10.1007/s11695-024-07501-0>.
12. Groene P., Eisenlohr J., Zeuzem C. et al. Postoperative nausea and vomiting in bariatric surgery in comparison to non-bariatric gastric surgery. *Wideochir Inne Tech Maloinwazyjne.* 2019;14:90–5. <https://doi.org/10.5114/wiitm.2018.77629>.
13. Suh S., Helm M., Kindel T. L. et al. The impact of nausea on post-operative outcomes in bariatric surgery patients. *Surg Endosc.* 2020;34:3085–91. <https://doi.org/10.1007/s00464-019-07058-5>.

Информация об авторах:

Хитарьян Александр Георгиевич, доктор медицинских наук, профессор, зав. кафедрой хирургических болезней № 3, Ростовский государственный медицинский университет, зав. хирургическим отделением, Клиническая больница «РЖД-Медицина» (г. Ростов-на-Дону, Россия), ORCID: 0000-0002-2108-2362, SPIN-код: 2843-6943; **Арут Ваграмович Межунц**, кандидат медицинских наук, ассистент кафедры хирургических болезней № 3, Ростовский государственный медицинский университет (г. Ростов-на-Дону, Россия), врач-хирург хирургического отделения, Клиническая больница «РЖД-Медицина» (г. Ростов-на-Дону, Россия), ORCID: 0000-0001-7787-4919, SPIN-код: 4263-4090; **Велиев Камил Савинович**, кандидат медицинских наук, врач-хирург хирургического отделения, Клиническая больница «РЖД-Медицина» (г. Ростов-на-Дону, Россия), ORCID: 0000-0002-0078-260X, SPIN-код: 3897-8895; **Орехов Алексей Анатольевич**, кандидат медицинских наук, доцент кафедры хирургических болезней № 3, Ростовский государственный медицинский университет, врач-хирург хирургического отделения, Клиническая больница «РЖД-Медицина» (г. Ростов-на-Дону, Россия), ORCID: 0000-0003-3782-2860, SPIN-код: 1717-9279; **Мельников Денис Андреевич**, кандидат медицинских наук, ассистент кафедры хирургических болезней № 3, Ростовский государственный медицинский университет, врач-хирург хирургического отделения, Клиническая больница «РЖД-Медицина» (Ростов-на-Дону, Россия),

ORCID: 0000-0002-1829-3345, SPIN-код: 7823-3911; **Пен Олег Сергеевич**, аспирант кафедры хирургических болезней № 3, Ростовский государственный медицинский университет (г. Ростов-на-Дону, Россия), ORCID: 0009-0007-4887-6502; **Пуковский Денис Юрьевич**, врач-хирург хирургического отделения, Клиническая больница «РЖД-Медицина» (г. Ростов-на-Дону, Россия), ORCID: 0009-0006-1370-0657; **Османян Ани Гамлетовна**, студентка 4 курса, Ростовский государственный медицинский университет (г. Ростов-на-Дону, Россия), ORCID: 0000-0002-4512-6657, SPIN-код: 4100-3999; **Потокова Зарина Ибрамовна**, студентка 4 курса, Ростовский государственный медицинский университет (г. Ростов-на-Дону, Россия), ORCID: 0009-0004-6614-1575, SPID-код: 5983-8964; **Гаспарян Арман Самвелович**, студент 3 курса, Ростовский государственный медицинский университет (г. Ростов-на-Дону, Россия), ORCID: 0000-0003-1254-7022.

Information about authors:

Khitaryan Alexander G., Dr. of Sci. (Med.), Professor, Head of the Department of Surgical Diseases № 3, Rostov State Medical University, Head of the Surgical Department, Clinical Hospital «RZD-Medicine» (Rostov-on-Don, Russia), ORCID: 0000-0002-2108-2362, SPIN-code: 2843-6943; **Mezhunts Arut V.**, Cand. of Sci. (Med.), Assistant of the Department of Surgical Diseases № 3, Rostov State Medical University, Surgeon of the Surgical Department, Clinical Hospital «RZD-Medicine» (Rostov-on-Don, Russia), ORCID: 0000-0001-7787-4919, SPIN-code: 4263-4090; **Veliev Kamil S.**, Cand. of Sci. (Med.), Surgeon of the Surgical Department, Clinical Hospital «RZD-Medicine» (Rostov-on-Don, Russia), ORCID: 0000-0002-0078-260X, SPIN-code: 3897-8895; **Orekhov Alexey A.**, Cand. of Sci. (Med.), Associate Professor of the Department of Surgical diseases № 3, Rostov State Medical University, Surgeon of the Surgical Department, Clinical Hospital «RZD-Medicine» (Rostov-on-Don, Russia), ORCID: 0000-0003-3782-2860, SPIN-code: 1717-9279; **Melnikov Denis A.**, Cand. of Sci. (Med.), Assistant of the Department of Surgical Diseases № 3, Rostov State Medical University, Surgeon of the Surgical Department, Clinical Hospital «RZD-Medicine» (Rostov-on-Don, Russia), ORCID: 0000-0002-1829-3345, SPIN-code: 7823-3911; **Pen Oleg S.**, Postgraduate Student of the Department of Surgical Diseases № 3, Rostov State Medical University (Rostov-on-Don, Russia), ORCID: 0009-0007-4887-6502; **Pukovsky Denis Y.**, Surgeon of the Surgical Department, Clinical Hospital «RZD-Medicine» (Rostov-on-Don, Russia), ORCID: 0009-0006-1370-0657; **Osmanian Ani G.**, 4th-year Student, Rostov State Medical University (Rostov-on-Don, Russia), ORCID: 0000-0002-4512-6657, SPIN-code: 4100-3999; **Potokova Zarina I.**, 4th-year Student, Rostov State Medical University (Rostov-on-Don, Russia), ORCID: 0009-0004-6614-1575, SPID-code: 5983-8964; **Gasparian Arman S.**, 3th-year Student, Rostov State Medical University (Rostov-on-Don, Russia), ORCID: 0000-0003-1254-7022, SPIN-code.