

<https://doi.org/10.23888/HMJ2025134603-614>

EDN: TXLWWL

Искусственный интеллект в оптимизации хирургического лечения тетрады Фалло: разработка и валидация прогностической модели

О.Ю. Тимофеева¹ , Д.С. Акатов¹, Е.В., А.Ю. Глазунов², Т.Р. Григорьянц¹, А.И. Ким¹, Т.В. Рогова¹, Д.Ю. Попеня³, М.С. Жуликова³

¹ Национальный медицинский исследовательский центр сердечно-сосудистой хирургии имени А.Н. Бакулева, Москва, Российская Федерация

² Экосистема Альфа, Москва, Российская Федерация

³ Российский национальный исследовательский медицинский университет имени Н.И. Пирогова (Пироговский Университет), Москва, Российская Федерация

Автор, ответственный за переписку: Тимофеева Ольга Юрьевна, otimofeevau@yandex.ru

АННОТАЦИЯ

Введение. Тетрада Фалло (ТФ) — наиболее распространенный цианотический врожденный порок сердца. Несмотря на успехи хирургии сохраняется высокая вариабельность послеоперационных исходов. Традиционные методы исследования не всегда позволяют точно прогнозировать риски осложнений.

Цель. Разработать модель машинного обучения, рекомендующую выбор оптимальной хирургической тактики на основе анализа клинических и инструментальных данных.

Материалы и методы. В рамках одноцентрового когортного исследования сформирован ретроспективный реестр клинико-инструментальных данных 300 детей с ТФ, перенесших первичное оперативное лечение в 2017–2022 годах. Целевая переменная представляла собой четырехклассовую категорию, соответствующую типу вмешательства. Фактически примененные хирургические стратегии распределились следующим образом: радикальная коррекция ТФ — 168 пациентов (57,1%), наложение системно-легочного анастомоза — 83 (28,2%), реконструкция путей/выводного тракта правого желудочка — 25 (8,5%), стентирование или баллонирование выводного отдела правого желудочка, включая транслюминальную баллонную вальвулопластику клапана легочной артерии — 24 (8,2%).

Результаты. Для решения задачи построена классификационная модель с внутренней валидацией. Модель продемонстрировала удовлетворительную прогностическую состоятельность. Наибольший вклад в принятие решения обеспечивали показатели оксигенации (сатурация крови кислородом), сосудисто-анатомические индексы Nakata и McGoon, градиент давления между правым желудочком и легочной артерией, а также объем левого желудочка. Полученные результаты указывают, что предложенная модель способна служить инструментом поддержки клинического выбора хирургической стратегии при ТФ, согласуя вычислительные предсказания с патофизиологически обоснованными предикторами.

Заключение. В контексте данного исследования, посвященного прогнозированию хирургической тактики при ТФ, применение 5-Fold кросс-валидации позволило убедиться в том, что модель LightGBM демонстрирует высокую точность не только на конкретном подмножестве данных, но и на всех пяти вариантах разбиения. Это подтверждает ее надежность и применимость в реальных клинических условиях.

Ключевые слова: тетрада Фалло; искусственный интеллект; машинное обучение; хирургическая тактика; прогностическая модель.

Для цитирования:

Тимофеева О.Ю., Акатов Д.С., Глазунов А.Ю., Ким А.И., Рогова Т.В., Попеня Д.Ю., Жуликова М.С. Искусственный интеллект в оптимизации хирургического лечения тетрады Фалло: разработка и валидация прогностической модели // Наука молодых (Eruditio Juvenium). 2025. Т. 13, № 4. С. 603–614. doi: 10.23888/HMJ2025134603-614 EDN: TXLWWL

<https://doi.org/10.23888/HMJ2025134603-614>

EDN: TXLWWL

Artificial intelligence in Optimizing Surgical Treatment of Tetralogy of Fallot: Development and Validation of Prognostic Model

Olga Yu. Timofeeva¹ , Denis S. Akatov¹, Alexandr Yu. Glazunov², Tigran R. Grigoryants¹, Aleksey I. Kim¹, Tatyana V. Rogova¹, Darina Yu. Popenya³, Maria S. Zhulikova³

¹ A.N. Bakulev National Medical Research Center of Cardiovascular Surgery, Moscow, Russian Federation

² Ekosistema Alfa, Moscow, Russian Federation

³ N.I. Pirogov Russian National Research Medical University (Pirogov University), Moscow, Russian Federation

Corresponding author: Olga Yu. Timofeeva, otimofeevau@yandex.ru

ABSTRACT

INTRODUCTION: Tetralogy of Fallot (TOF) is the most common cyanotic congenital heart defect. With traditional examination methods precise prediction of complication risks is not always possible.

AIM: To develop a machine learning model that recommends the optimal surgical tactics based on the analysis of clinical and instrumental data.

MATERIALS AND METHODS: As part of a single-center cohort study, a retrospective registry was formed of clinical and instrumental data from 300 children with TOF who underwent primary surgical treatment in 2017–2022. The target variable was a four-class category corresponding to the type of intervention. The used surgical strategies were distributed as follows: radical TOF correction — 168 patients (57.1%), creation of a systemic-pulmonary anastomosis — 83 (28.2%), reconstruction of the outflow ways/tract from the right ventricle — 25 (8.5%), stenting or ballooning of the right ventricular outflow tract, including transluminal balloon plasty of the pulmonary valve — 24 (8.2%).

RESULTS: To address this problem, a classification model with internal validation was constructed. The gradient boosting model demonstrated satisfactory predictive validity. Contributed most to the decision-making process: oxygenation parameters (blood oxygen saturation), the Nakata and McGoon vascular-anatomical indices, the pressure gradient between the right ventricle and pulmonary artery, and the left ventricular volume. The obtained results indicate that the proposed model can serve as a tool for supporting clinical choice of surgical strategy in TOF by aligning computational predictions with pathophysiologically justified predictors.

CONCLUSION: In the context of this study on predicting surgical tactics in TOF, the use of 5-Fold cross-validation made it possible to verify that the LightGBM model demonstrates high accuracy not only on a specific subset of data, but also on all five partitioning options. This confirms its reliability and applicability in real clinical conditions.

Keywords: tetralogy of Fallot; artificial intelligence; machine learning; surgical tactics; predictive model.

To cite this article:

Timofeeva OYu, Akatov DS, Glazunov AYu, Grigoryants TR, Kim AI, Rogova TV, Popenya DYu, Zhulikova MS. Artificial Intelligence in Optimizing Surgical Treatment of Tetralogy of Fallot: Development and Validation of Prognostic Model. *Science of the Young (Eruditio Juvenium)*. 2025;13(4):603–614. doi: 10.23888/HMJ2025134603-614 EDN: TXLWWL

Введение

Тетрада Фалло (ТФ) — наиболее распространенный цианотический врожденный порок сердца (ВПС) — 7–10% [1, 2]. Несмотря на успехи хирургии сохраняется высокая вариабельность послеоперационных исходов, связанная с разнообразием анатомических вариантов и субъективностью выбора тактики [3–7]. Традиционные методы (ЭхоКГ, ангиография) не всегда позволяют точно прогнозировать риски осложнений, таких как легочная регургитация (ЛР) или дисфункция правого желудочка (ПЖ) [8–10].

Искусственный интеллект (ИИ), особенно методы машинного обучения (МО), предлагают новые возможности для анализа комплексных данных и поддержки принятия решений. Современные достижения в лечении ТФ значительно улучшили выживаемость пациентов, однако выбор оптимальной хирургической тактики остается сложной задачей из-за вариабельности анатомии порока и послеоперационных исходов.

Цель — разработать модель МО на основе алгоритма LightGBM (LGBM Classifier), рекомендующую выбор оптимальной хирургической тактики на основе анализа клинических и инструментальных данных.

Материалы и методы

В рамках одноцентрового когортного исследования сформирован ретроспективный реестр клинико-инструментальных данных 300 детей с ТФ после первичного оперативного лечения в 2017–2022 годах. Прогнозируемой (целевой) переменной выступал тип хирургического вмешательства, представленный четырьмя категориями.

Критерии включения: первично оперированные пациенты с ТФ.

Критерии исключения: больные с сопутствующими ВПС, повторные и комбинированные вмешательства.

Реально примененные тактики распределились следующим образом: радикальная коррекция ТФ — 168 случаев (57,1%), наложение системно-легочного

анастомоза (СЛА) — 83 (28,2%), реконструкция путей/выводного тракта правого желудочка — 25 (8,5%), стентирование либо баллонная дилатация выводного отдела правого желудочка, включая транслюминальную баллонную вальвулопластику клапана легочной артерии — 24 (8,2%). Все сведения были извлечены из медицинских информационных систем и деперсонифицированы перед анализом.

Данные разделяли на обучающую и отложенную подвыборки в соотношении 70/30; обучение выполняли на первом фрагменте, а качество затем проверяли на «hold-out». Для контроля переобучения использовали пятикратную (5-fold) перекрестную проверку. В качестве основных моделей тестировали случайный лес и градиентный бустинг, а референсный ориентир по метрикам получали на логистической регрессии. После завершения обучения итоговый предиктор дополнительно верифицировали на тестовой части датасета.

Градиентный бустинг — ансамблевая схема МО, в которой слабые алгоритмы (чаще всего решающие деревья) добавляются итеративно, а каждый следующий компонент нацелен на компенсацию ошибок уже построенной композиции. Инициализация выполняется простой базовой моделью — например, константным предсказанием среднего по целевой переменной; затем вычисляются остатки (ошибки прогноза), которые служат целями для последующих шагов обучения. Следующая модель обучается уже на этих ошибках, а не на исходных данных, и так повторяется многократно. Итоговый прогноз представляет собой взвешенную сумму предсказаний всех моделей. Ключевая особенность градиентного бустинга — минимизация функции потерь через градиентный спуск, что и дало методу его название. Однако метод склонен к переобучению, поэтому важно контролировать гиперпараметры, такие как глубина деревьев (`max_depth`), скорость обучения (`learning_rate`) и количество итераций (`n_estimators`). Градиентный бустинг особенно эффективен для работы с табличными данными и часто показывает

высокие результаты в соревнованиях по МО, таких как Kaggle.

Случайный лес — это также ансамблевый метод, но в отличие от бустинга, он строит множество деревьев независимо и параллельно, а не последовательно. В модели случайного леса каждое дерево строится на бутстреп-подвыборке исходных наблюдений, а при каждом разбиении узла рассматривается лишь случайный поднабор признаков. Такая двойная стохастизация уменьшает корреляцию между деревьями и, как следствие, снижает риск переобучения. Итоговое предсказание формируется агрегированием откликов всех деревьев: в регрессии — через усреднение, в классификации — через мажоритарное голосование. Случайный лес менее чувствителен к настройке гиперпараметров по сравнению с градиентным бустингом и хорошо справляется с зашумленными данными. Он также позволяет оценивать важность признаков на основе того, насколько они улучшают качество разбиений в деревьях. Оба метода — и градиентный бустинг, и случайный лес — являются мощными инструментами для решения задач классификации и регрессии, но их выбор зависит от конкретной задачи и характеристик данных.

5-Fold кросс-валидация представляет собой важный метод оценки и валидации моделей МО, который позволяет более точно оценить их обобщающую способность и избежать переобучения. Суть метода заключается в том, что исходный набор данных случайным образом разбивается на

5 равных частей, называемых фолдами. Затем процесс обучения и валидации повторяется 5 раз, причем каждый раз одна из частей (20% данных) поочередно используется в качестве тестового набора, а остальные четыре части (80% данных) — в качестве обучающего набора. После завершения всех пяти итераций результаты оценки модели усредняются, что позволяет получить более надежную и устойчивую оценку ее производительности.

Основное преимущество 5-Fold кросс-валидации заключается в том, что каждый элемент данных используется как для обучения, так и для тестирования, что минимизирует влияние случайного разделения данных на конечный результат. Это особенно важно при работе с небольшими наборами данных, где традиционное разделение на обучающую и тестовую выборки может привести к значительным колебаниям в оценке качества модели. Кроме того, метод помогает выявить переобучение, так как модель проверяется на разных подмножествах данных, и ее производительность должна оставаться стабильной во всех интеграциях.

Результаты

LGBMClassifier (LightGBM) показал наилучший результат на тестовой выборке (0.8180), что свидетельствует о его хорошей способности к обобщению. При этом его результат на тренировочной выборке (0.7652) лишь немного выше, чем у CatBoost (0.7631), что указывает на отсутствие переобучения (табл. 1).

Таблица 1. Сравнение показателей метрики F1 макро-алгоритмов машинного обучения на тренировочной и тестовой выборках

Table 1. Comparison of F1 metric parameters of macro-ML algorithms on training and test samples

Алгоритм	Метрика F1 макро	
	Тренировочная выборка	Тестовая выборка
LogisticRegression	0,5788	0,5973
RandomForestClassifier	0,6972	0,6280
LGBMClassifier	0,7652	0,8180
XGBClassifier	0,7479	0,6660
CatBoostClassifier	0,7631	0,7037

Использование данной метрики позволяет лучше выбрать модель, которая не только точно классифицирует различные случаи, но и минимизирует количество пропущенных данных. Представленная таблица демонстрирует результаты сравнения пяти алгоритмов МО по метрике F1-макро на тренировочной и тестовой выборках. F1-макро — это среднее гармоническое между точностью (precision) и полнотой (recall), вычисленное для каждого класса отдельно с последующим усреднением, что особенно полезно при несбалансированных данных.

Качество моделей было оценено с помощью AUC-площади (Area Under Curve) под ROC-кривой (Receiver Operating Characteristics curve), выраженной через отношение доли истинно положительных прогнозов (TPR) к доле ложноположительных (FPR). ROC-кривые для пяти моделей представлены на рисунке 1.

Качество моделей было оценено с помощью AUC-площади (Area Under Curve) под ROC-кривой (Receiver Operating Characteristics curve), выраженной через отношение доли истинно положительных прогнозов (TPR) к доле ложноположительных (FPR). ROC-кривые для пяти моделей представлены на рисунке 1.

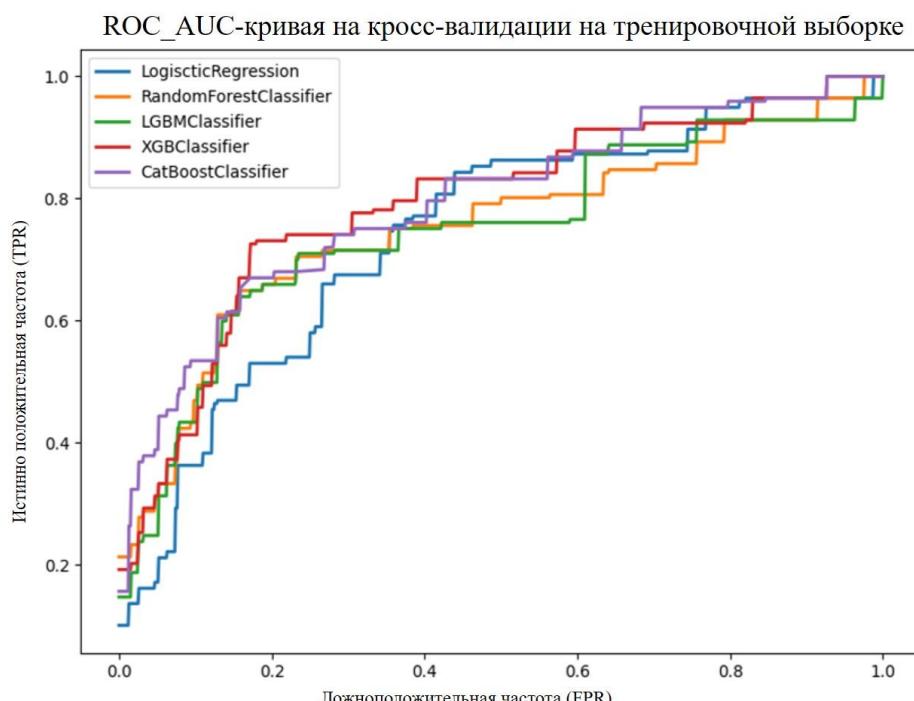


Рис. 1. ROC-кривые сравнения всех используемых моделей машинного обучения.

На представленном графике изображены ROC-кривые (Receiver Operating Characteristic) пяти различных алгоритмов машинного обучения, оцененные с помощью макро-усреднения на кросс-валидации.

Крутой подъем кривых в начале (левый край графика) свидетельствует о высокой чувствительности моделей — они правильно идентифицируют значительную долю положительных случаев при низком уровне ложных срабатываний. Плато в верхней части кривых указывает на то, что дальнейшее увеличение True Positive Rate (TPR, истинно положительная частота) требует значительного роста False Positive Rate (FPR, ложноположительная частота).

Fig. 1. ROC-curves of comparison of all machine learning models used.

Graph shows five different machine learning algorithm ROC-curves, evaluated using macro-averaging on cross-validation.

The initial steep rise of the curves (left part of the graph) indicates high sensitivity of models — they correctly identify a significant proportion of positive cases with a low false positive rate. Plateau on the top of the curves indicates that further increases in the True Positive Rate require a significant increase in the False Positive Rate.

Все модели демонстрируют достаточно высокую производительность (AUC >0.8), что указывает на хорошую способность различать классы. CatBoostClassifier

и XGBClassifier, судя по визуальному анализу кривых, показывают наилучшие результаты (их кривые ближе к левому верхнему углу). LogisticRegression, как

правило, уступает ансамблевым методам, что ожидаемо для сложных данных.

Важность признаков для моделей представлена на рисунке 2.

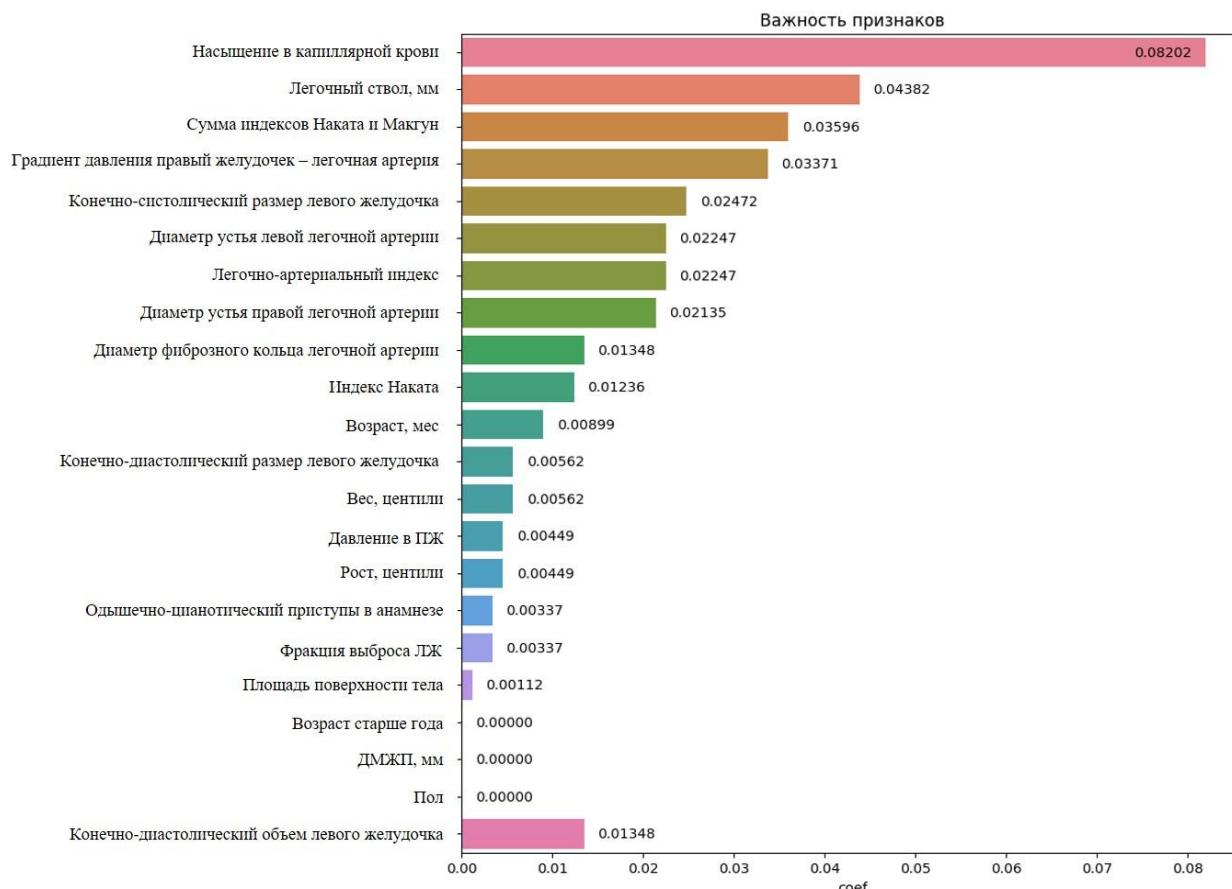


Рис. 2. Интерпретация важности признаков в модели машинного обучения.
Fig. 2. Interpretation of the significance of parameters in machine learning model.

Наибольший вклад в решение модели внесли признаки высокой значимости. Лидировал показатель насыщения капиллярной крови кислородом SpO_2 (0.08202) — фактически главный детерминант, что подчеркивает его критическую роль для прогнозируемого исхода. Далее следовал диаметр ствола легочной артерии (0.04382), отражающий анатомические особенности легочного русла. Существенным оказался и показатель \log — натуральный логарифм произведения величин АВнАО и ЛАИ пациента (где АВнАО трактуется как отношение суммы диаметров устьев легочных артерий к диаметру нисходящей аорты, умноженное на легочно-артериальный индекс) — 0.03596; это логарифмированная интегральная метрика. Значимым гемодина-

мическим фактором выступал градиент давления ПЖ/ЛА (0.03371), характеризующий перепад между правым желудочком и легочной артерией. Дополнял группу ключевых предикторов конечно-диастолический размер левого желудочка (КДР ЛЖ), (0.02472). Перечисленные параметры определяли большую часть дискриминирующей способности модели и, следовательно, подлежат особенно тщательному мониторингу в клинической практике.

К признакам средней важности относились диаметры устьев легочных артерий (0.02247 и 0.02135) и сам легочно-артериальный индекс (0.02247), диаметр фиброзного кольца клапана легочной артерии (0.01348), а также индекс Наката (0.01236) — все они преимущественно описывают морфологию и калибр сосудистого

русле легких. Возраст пациента (0,00899), выраженный в месяцах, играл дополнительную роль, что ожидаемо для педиатрических выборок. Эти переменные обеспечивали умеренный, но стабильный вклад в предсказание и игнорироваться при интерпретации результатов не должны.

При разделении на подгруппы в зависимости от числа обострений ХОБЛ (≥ 2 и <2 обострений ХОБЛ в течение года) различий по возрасту ($p=0,6826$) и полу ($p=1,0$) выявлено не было. В подгруппе пациентов,

имеющих ≥ 2 обострений ХОБЛ в течение года в сравнении с подгруппой пациентов, имеющих <2 обострений ХОБЛ в течение года ФП встречалась чаще (ОШ 4,80, 95% ДИ 1,74–14,73, $p=0,0011$). Кроме того, были более выражены степень митральной регургитации ($p=0,0039$) и степень триkusпидальной регургитации ($p=0,0455$). При выделении подгрупп по возрасту, значениям ОФВ₁, выраженности одышки по mMRS статистически-значимых различий выявлено не было (табл. 3).

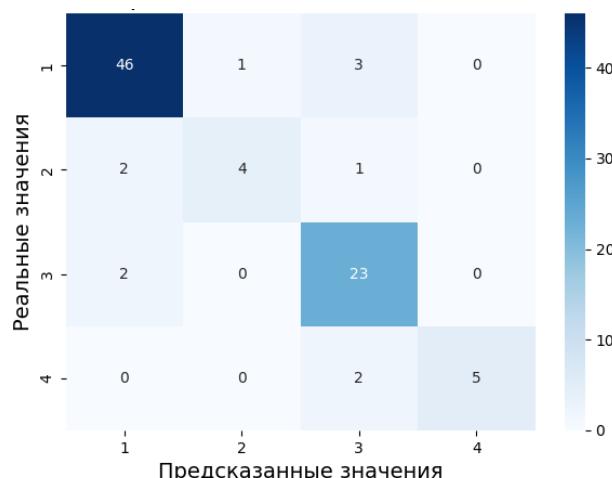


Рис. 3. Матрица ошибок модели LGBMClassifier (данная модель показала наилучшие результаты и точность в способности к рекомендациям).

Fig. 3. Error matrix of LGBMClassifier model (this model showed the best results and accuracy in the ability to make recommendations).

Обсуждение

МО и ИИ все шире применяются для прогнозирования рисков и поддержки принятия решений у пациентов, в том числе с ТФ. В исследованиях, имеющихся в свободном доступе в мировой литературе, использовались различные методы, включая глубокое обучение, случайный лес, метод опорных векторов и модели с градиентным бустингом, для прогнозирования таких исходов, как серьезные неблагоприятные сердечно-сосудистые события, результаты хирургического вмешательства и дисфункция желудочков (табл. 2).

Производительность ИИ оценивалась изолированно, а также в сравнении с мнением врача-эксперта: эффективность

МО оценивалась в пяти исследованиях [11–15] с помощью ROC-AUC анализа, она была в диапазоне от 0,81 до 0,85, что говорит о хорошей способности МО к обучаемости и прогнозированию. В исследовании F.P. Lo Muzio и соавт. (2021) сообщалось о достоверности результатов $\geq 95\%$ [16]. В двух исследованиях, в которых сравнивались результаты ИИ и мнение врача-эксперта, оба показали, что эффективность работы эксперта (AUC=0,98 в 1-м случае и AUC=0,92 — во 2-м) была выше, чем у ИИ (AUC=0,85). В обоих случаях совокупная эффективность (AUC=0,85) соответствовала эффективности ИИ (см. табл. 2).

Ключевым аспектом анализа для большинства авторов являлась оценка потенциала ИИ для поддержки принятия

Таблица 2. Модели прогнозирования рисков, используемые по данным мировой литературы
Table 2. Risk prediction models used in modern literature

Авторы и год исследования	Тип модели ИИ	Показатели производительности	Клиническое применение	Метод валидации
Diller et al., 2020	Глубокое обучение	–	Прогнозирование исхода операции	–
Wald et al., 2023	Случайный лес	Площадь под кривой AUC: 0,82 (95% ДИ 0,74–0,89)	Прогнозирование основных неблагоприятных сердечно-сосудистых событий после операции у взрослых пациентов с диагнозом ТФ	Повторная проверка случайной подвыборки
Lo Muzio et al., 2021	Метод k-ближайших соседей (K-Nearest Neighbors, KNN)	Доля истинно положительных результатов : >95%	Прогнозирование исхода операции	10-кратная перекрестная проверка
Samad et al., 2018	Метод опорных векторов (Support Vector Machine, SVM)	Площадь под кривой AUC: $0,82 \pm 0,06$ (любое ухудшение), $0,77 \pm 0,07$ (значительное ухудшение)	Прогнозирование ухудшения функции желудочков	Пятикратная перекрестная проверка
Xi et al., 2023	Логистическая регрессия, байесовский метод Гаусса	–	Прогнозирование неблагоприятных исходов после коррекции ТФ	–
Ishikita et al., 2022	Случайный лес	AUC: 0,81 (95% ДИ 0,75–0,86) для тестового набора данных, 0,88 (95% ДИ 0,71–0,99) для обучающей выборки	Прогнозирование основных неблагоприятных сердечно-сосудистых событий после операции у взрослых пациентов с диагнозом ТФ	Повторная проверка случайной подвыборки
Ishikita et al., 2023	–	AUC: 0,85 (95% ДИ 0,61–0,95)	Прогнозирование основных неблагоприятных сердечно-сосудистых событий после операции у взрослых пациентов с диагнозом ТФ	–
Ishikita et al., 2023	–	AUC: 0,85 (95% ДИ 0,58–0,96)	Прогнозирование основных неблагоприятных сердечно-сосудистых событий после операции у взрослых пациентов с диагнозом ТФ	–
Jimenez-Perez et al., 2022	Глубокое обучение	–	Выявление подгрупп высокого риска на основе ЭКГ	–
Faerber et al., 2021	Модели квантильной регрессии с градиентным бустингом, модели регрессии пуассона с градиентным бустингом	–	Прогнозирование послеоперационных осложнений	Перекрестная проверка

клинических решений (см. табл. 2). A. Ishikita и соавт. (2022) [12] сообщили, что их модель МО превзошла традиционную многофакторную модель Кокса (статистический метод, используемый для анализа данных выживаемости, в которых важно влияние нескольких факторов (предикторов) на вероятность наступления события (например, смерти, рецидива заболевания, отказа оборудования) во времени) в прогнозировании рисков со стороны сердечно-сосудистой системы (AUC 0,82 против 0,63, $p=0,003$). F.P. Lo Muzio и соавт. [16] сообщили, что их модель ИИ может прогнозировать результаты хирургического вмешательства с высокой долей истинно положительных результатов ($\geq 95\%$). J.A. Faerber и соавт. (2021) выявили факторы риска послеоперационных осложнений [17].

Два исследования, проведенные A. Ishikita и соавт. (2022, 2023), позволили лучше понять, как ИИ интегрируется с клиническим опытом (см. табл. 2) [12, 13]. В обоих исследованиях эффективность модели ИИ (AUC=0,85) была сопоставима с совокупной эффективностью врачей-экспертов (AUC=0,92). Модель ИИ обеспечила дополнительную ценность в сочетании с суждениями менее опытных врачей, приблизив их работу к работе более опытных специалистов. Однако важно отметить, что в этих исследованиях использовалась небольшая выборка ($n=25$) для подтверждения результатов.

Используемая в данном исследовании модель LightGBM показала высокую прогностическую ценность, особенно при прогнозировании выполнения радикальной коррекции и наложения СЛА. Это согласуется с международными исследованиями, где ИИ использовался для стратификации риска при ТФ [17, 18].

Полученные результаты (F1-score 0.818) сопоставимы с данными зарубежных коллег: например, J.A. Faerber и соавт. (2021) при использовании логистической регрессии и метода наивного Байеса достигли точности прогнозирования послеоперационных осложнений на уровне

78–85% [17]. Важно отметить, что полученные ключевые предикторы — насыщение крови кислородом, индексы Nakata и MCGoon — полностью соответствуют параметрам, которые L. Xi и соавт. (2023) выделили как наиболее значимые в своем исследовании с участием 512 пациентов [18]. В статье S. Nurmaini и соавт. (2022) представлена нейросетевая модель для пренатальной диагностики ВПС с точностью 95–100% на основе анализа ультразвуковых изображений и данных фетальной ЭхоКГ [19]. Высокая точность алгоритма (превышающая традиционные методы) подтверждает, что глубокое обучение может значительно улучшить раннюю диагностику ВПС. Автоматизация анализа снижает субъективность в интерпретации изображений, что особенно важно в пренатальной кардиологии. Раннее выявление позволяет оптимизировать планирование хирургической коррекции сразу после рождения, улучшая прогноз. Данное исследование подчеркивает, что ИИ-алгоритмы могут достигать исключительной точности в узкоспециализированных задачах, таких как диагностика ВПС. Это открывает путь для их внедрения на всех этапах кардиохирургической помощи — от пренатальной диагностики до послеоперационного мониторинга.

Отличительной особенностью данного исследования стало включение в анализ центильных показателей физического развития, что редко встречается в международных работах, но, как показали результаты, значительно улучшило прогностическую способность модели. При этом мы столкнулись с теми же ограничениями, что и зарубежные коллеги, в частности, с проблемой «черного ящика» (феномен, описывающий неинтерпретируемость алгоритмов ИИ, особенно — глубокого обучения). Модель выдает результат алгоритмов МО (например, прогноз осложнений после операции), но не объясняет, как она его получила.

Полученные данные о высокой значимости градиента правый желудочек–легочная артерия и объемы левого желу-

дочка полностью согласуются с результатами, опубликованными в крупном международном исследовании EACTS Congenital Database [20]. Однако полученная модель превзошла традиционные статистические подходы в точности прогнозирования, что особенно заметно при анализе подгруппы пациентов, которым была выполнена радикальная коррекция (точность рекомендаций 89%). Этот результат особенно важен в контексте современных тенденций к минимизации инвазивных вмешательств при ТФ, описанных J. Villafañe и соавт. (2013) [21].

Перспективным направлением для дальнейших исследований представляется интеграция полученной модели с системами поддержки принятия решений на основе ИИ, подобными тем, которые разрабатываются для анализа аускультативной картины [22] и автоматической обработки эхокардиографических изображений [23].

Особенно важно, что полученная модель, в отличие от многих зарубежных аналогов, была валидирована на данных реальной клинической практики, включая случаи с неполными показателями, что повышает ее потенциальную применимость в рутинной работе кардиохирургических центров.

Заключение

Полученные результаты показывают, что модели искусственного интеллек-

та могут обеспечить более точную стратификацию рисков, чем традиционные статистические методы, и потенциально могут помочь в принятии хирургических решений и периоперационном ведении пациентов. ИИ может стать ценным инструментом для принятия клинических решений, особенно для начинающих специалистов. Модель на основе LightGBM доказала эффективность в рекомендации хирургической тактики при ТФ. Дальнейшие исследования должны быть направлены на ее клиническую апробацию и интеграцию в практику.

Ограничения исследования. Разработанная модель продемонстрировала высокую эффективность на внутренних данных нашего центра, однако необходимо дальнейшее независимое тестирование на когортах пациентов из других специализированных кардиохирургических учреждений. Это также позволит выявить и нивелировать возможные межцентровые различия в хирургических подходах. Несмотря на удовлетворительную общую производительность, точность прогноза для менее распространенных типов вмешательств оставляет возможность для улучшения. Настоящее исследование было сфокусировано на технической разработке и внутренней валидации модели. Следующим шагом является ее проспективная внешняя валидация.

Список литературы | References

1. Kim AI, Grigoryants TR, Timofeeva OYu. Treatment strategies for tetralogy of Fallot: radical correction, pulmonary valve reconstruction, right ventricular remodeling. *Children's Heart and Vascular Diseases*. 2023;20(2):100–109. doi: 10.24022/1810-0686-2023-20-2-100-109 EDN: GOUNAF
2. Golukhova EZ. Report on the scientific and clinical activity of Bakoulev National Medical Research Center for Cardiovascular Surgery for 2023 and development prospects. *The Bulletin of Bakoulev Center. Cardiovascular Diseases*. 2024; 25(S):5–141. doi: 10.24022/1810-0694-2024-25S EDN: JIEAVY
3. Shatalov KV, Dzhidzhikhiya KM, Arnautova IV, Abdurazakov MA. Repair of tetralogy of Fallot using designed PTFE monocusp patch. *Children's Heart and Vascular Diseases*. 2020;17(1):58–60. doi: 10.24022/1810-0686-2020-17-1-58-60 EDN: DRBNSV
4. Shcherbak AV, Zelenikin MM, Britikov DV, Zelenikin MA. Immediate results of the right ventricular outflow tract reconstruction using an allopulmonary patch with one-leaflet closing element. *Children's Heart and Vascular Diseases*. 2021;18(2):104–109. doi: 10.24022/1810-0686-2021-18-2-104-109 EDN: UJPTRV
5. Dorokhina ES, Chernogrivov AE, Nefedova IE. Outcomes of valve-sparing procedures in radical correction of conotruncal defects with pulmonary blood flow obstruction in the world. *Children's Heart and Vascular Diseases*. 2024; 21(2):79–88. doi: 10.24022/1810-0686-2024-21-2-79-88 EDN: KUMJWC

6. Atmashkin AA, Kim AI, Rogova TV, et al. Tetralogy of Fallot: transatrial reconstruction of the right ventricle outlet tract with the hypoplastic pulmonary valve preservation in infants. *Children's Heart and Vascular Diseases*. 2023;20(2):87–99. doi: 10.24022/1810-0686-2023-20-2-87-99 EDN: AFFDMY
7. Lyapin A. A., Tarasov R.S. Transannular plastic surgery for radical correction of Fallot's tetrad — what is next? *Creative Cardiology*. 2025;19(2): 146–154. doi: 10.24022/1997-3187-2025-19-2-146-154 EDN: KWQBME
8. Mironenko MYu, Bockeria LA. Four-dimensional, three-dimensional echocardiography and imaging in cardiac surgery. *The Bulletin of Bakoulev Center. Cardiovascular Diseases*. 2021;22(1):21–39. doi: 10.24022/1810-0694-2021-22-1-21-39 EDN: WODKXP
9. Wilson R, Ross O, Griksaitis MJ. Tetralogy of Fallot. *BJA Educ*. 2019;19(11):362–369. doi: 10.1016/j.bjae.2019.07.003
10. Malozemova OG, Gasanova RM, Medvedeva IB, et al. Transthoracic echocardiography of the double aortic arch in a newborn. *Neonatology: News, Opinions, Training*. 2022; 10(2):43–49. doi: 10.33029/2308-2402-2022-10-2-43-49 EDN: PTCSFR
11. Ishikita A, McIntosh C, Hanneman K, et al. Machine Learning for Prediction of Adverse Cardiovascular Events in Adults With Repaired Tetralogy of Fallot Using Clinical and Cardiovascular Magnetic Resonance Imaging Variables. *Circ Cardiovasc Imaging*. 2023; 16(6):e015205. doi: 10.1161/circimaging.122.015205 EDN: YXLLOS
12. Ishikita A, McIntosh C, Lee MM, et al. Abstract 12563: Creation of an Artificial Intelligence Model For Prediction of Major Adverse Cardiovascular Events Late After Tetralogy of Fallot Repair. *Circulation*. 2022;146(S1): 12563. doi: 10.1161/circ.146.suppl_1.12563 EDN: VBPXQA
13. Ishikita A, McIntosh C, Roche SL, et al. Abstract 13861: Risk Prediction in Adults Late After Tetralogy of Fallot Repair: Does Machine Learning Provide Incremental Value Above Expert Clinical Judgement? *Circulation*. 2023;148(S1):13861. doi: 10.1161/circ.148.suppl_1.13861 EDN: ZPVXWA
14. Ishikita A, McIntosh C, Roche SL, et al. Incremental value of machine learning for risk prediction in tetralogy of Fallot. *Heart*. 2024;110(8):560–568. doi: 10.1136/heartjnl-2023-323296 EDN: FRBVTN
15. Samad MD, Wehner GJ, Arbabbirani MR, et al. Predicting deterioration of ventricular function in patients with repaired tetralogy of Fallot using machine learning. *Eur Heart J Cardiovasc Imaging*. 2018;19(7):730–738. doi: 10.1093/ehjci/jey003
16. Lo Muzio FP, Rozzi G, Rossi S, et al. Artificial Intelligence Supports Decision Making during Open-Chest Surgery of Rare Congenital Heart Defects. *J Clin Med*. 2021;10(22):5330. doi: 10.3390/jcm10225330 EDN: KOYVWW
17. Faerber JA, Huang J, Zhang X, et al. Identifying Risk Factors for Complicated Post-operative Course in Tetralogy of Fallot Using a Machine Learning Approach. *Front Cardiovasc Med*. 2021; 8:685855. doi: 10.3389/fcvm.2021.685855 EDN: FMMOYK
18. Xi L, Xiang M, Wu Ch, et al. Adverse events after repair of tetralogy of Fallot: prediction models by machine learning of a retrospective cohort study in western China. *Transl Pediatr*. 2023;12(2):125–136. doi: 10.21037/tp-22-246 EDN: KUQCBM
19. Nurmaini S, Partan RU, Bernolian N, et al. Deep Learning for Improving the Effectiveness of Routine Prenatal Screening for Major Congenital Heart Diseases. *J Clin Med*. 2022; 11(21):6454. doi: 10.3390/jcm11216454 EDN: TWQEAS
20. Jacobs JP, Jacobs ML, Maruszewski B, et al. Current status of the European Association for Cardio-Thoracic Surgery and the Society of Thoracic Surgeons Congenital Heart Surgery Database. *Ann Thorac Surg*. 2005; 80(6):2278–2283; 2283–2284. doi: 10.1016/j.athoracsur.2005.05.107 Erratum in: *Ann Thorac Surg*. 2010;89(4):1339. doi: 10.1016/j.athoracsur.2009.11.011
21. Villafaña J, Feinstein JA, Jenkins KJ, et al.; Adult Congenital and Pediatric Cardiology Section, American College of Cardiology. Hot topics in tetralogy of Fallot. *J Am Coll Cardiol*. 2013;62 (23):2155–2166. doi: 10.1016/j.jacc.2013.07.100
22. Thompson WR, Reinisch AJ, Unterberger MJ, Schriegl AJ. Artificial Intelligence-Assisted Auscultation of Heart Murmurs: Validation by Virtual Clinical Trial. *Pediatr Cardiol*. 2019; 40(3):623–629. doi: 10.1007/s00246-018-2036-z EDN: SEMKYD
23. Yu L, Guo Y, Wang Y, et al. Segmentation of Fetal Left Ventricle in Echocardiographic Sequences Based on Dynamic Convolutional Neural Networks. *IEEE Trans Biomed Eng*. 2017; 64(8):1886–1895. doi: 10.1109/TBME.2016.2628401

Дополнительная информация

Этическая экспертиза не проводилась.

Согласие на публикацию. Все участники исследования добровольно подписали форму информированного согласия до включения в исследование.

Источники финансирования. Отсутствуют.

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

Ethics approval was not conducted

Consent for publication. All participants of study voluntary signed an informed consent form before being included in the study.

Funding sources. No funding.

Disclosure of interests. The authors have no relationships, activities or interests for the last three years related with for-profit or not-for-profit third parties whose interests may be affected by the content of the article.

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

Генеративный искусственный интеллект. При создании статьи технологии генеративного искусственного интеллекта не использовали.

Рецензирование. В рецензировании участвовали два рецензента и член редакционной коллегии издания.

Об авторах:

✉ **Тимофеева Ольга Юрьевна**, врач сердечно-сосудистый хирург отделения реконструктивной хирургии новорожденных и детей первого года жизни с врожденными пороками сердца; адрес: Российская Федерация, 121552, Москва, Рублевское шоссе, д. 135; eLibrary SPIN: 9121-5387; ORCID: 0000-0003-0666-3529; e-mail: otimofeevau@yandex.ru

Акатов Денис Сергеевич, канд. мед. наук, врач сердечно-сосудистый хирург отделения реконструктивной хирургии новорожденных и детей первого года жизни с врожденными пороками сердца; eLibrary SPIN: 3494-7861; ORCID: 0000-0002-8401-2556; e-mail: dsakatov@bakulev.ru

Глазунов Александр Юрьевич, специалист по обработке данных; ORCID: 0009-0002-3818-3300; e-mail: ayuglazunov92@mail.ru

Григорьянц Тигран Рачикович, канд. мед. наук, врач сердечно-сосудистый хирург, ведущий научный сотрудник отделения реконструктивной хирургии новорожденных и детей первого года жизни с врожденными пороками сердца; eLibrary SPIN: 3283-9661; ORCID: 0000-0001-9344-2593; e-mail: trgrigoryants@bakulev.ru

Ким Алексей Иванович, д-р мед. наук, профессор, заведующий отделом кардиохирургии новорожденных и детей младенческого возраста; eLibrary SPIN: 6014-8178; ORCID: 0000-0003-0065-7419; e-mail: aikim@bakulev.ru

Рогова Татьяна Владимировна, д-р мед. наук, заведующий отделением реконструктивной хирургии новорожденных и детей первого года жизни с врожденными пороками сердца; eLibrary SPIN: 4096-7048; ORCID: 0000-0002-7610-1743; e-mail: tvrogova@bakulev.ru

Попеня Дарина Юрьевна, студент 6 курса педиатрического факультета; ORCID: 0009-0002-8566-9493; e-mail: darina_popenya@mail.ru

Жуликова Мария Петровна, студент 6 курса педиатрического факультета; ORCID: 0009-0008-8941-8505; e-mail: marimarigu@yandex.ru

Вклад авторов:

Тимофеева О.Ю. — сбор клинического материала, сбор и анализ данных, написание текста; Акатов Д.С. — обработка данных; Глазунов А.Ю. — статистическая обработка; Григорьянц Т.Р. — анализ и интерпретация данных; Ким А.И. — концепция и дизайн исследования; Рогова Т.В. — проверка критически важного содержания; Попеня Д.Ю. — сбор клинического материала; Жуликова М.П. — подготовка литературного обзора. Все авторы одобрили рукопись (версию для публикации), а также согласились нести ответственность за все аспекты работы, гарантируя надлежащее рассмотрение и решение вопросов, связанных с точностью и добросовестностью любой ее части.

Statement of originality. The authors did not use previously published information (text, illustrations, data) when creating this work.

Generative AI. Generative AI technologies were not used for this article creation.

Provenance and peer-review. Two reviewers and the member of the editorial board of the publication participated in the review.

Authors' Info

✉ **Olga Yu. Timofeeva**, Cardiovascular Surgeon of the Department of Reconstructive Surgery of Newborns and Children of the First Year of Life with Congenital Heart Defects; address: 135 Rublevskoye Shosse, Moscow, Russian Federation, 121552; eLibrary SPIN: 9121-5387; ORCID: 0000-0003-0666-3529; e-mail: otimofeevau@yandex.ru

Denis S. Akatov, MD, Cand. Sci. (Medicine), Cardiovascular Surgeon of the Department of Reconstructive Surgery of Newborns and Children of the First Year of Life with Congenital Heart Defects; eLibrary SPIN: 3494-7861; ORCID: 0000-0002-8401-2556; e-mail: dsakatov@bakulev.ru

Aleksandr Yu. Glazunov, Data Processing Specialist; ORCID: 0009-0002-3818-3300; e-mail: ayuglazunov92@mail.ru

Tigran R. Grigoryants, MD, Cardiovascular Surgeon, Leading Researcher of the Department of Reconstructive Surgery of Newborns and Children of the First Year of Life with Congenital Heart Defects; eLibrary SPIN: 3283-9661; ORCID: 0000-0001-9344-2593; e-mail: trgrigoryants@bakulev.ru

Aleksey I. Kim, MD, Dr. Sci. (Medicine), Professor, Head of the Department of Cardiac Surgery of Newborns and Infants; eLibrary SPIN: 6014-8178; ORCID: 0000-0003-0065-7419; e-mail: aikim@bakulev.ru

Tatyana V. Rogova, MD, Dr. Sci. (Medicine), Head of the Department of Reconstructive Surgery of Newborns and Children of the First Year of Life with Congenital Heart Defects; eLibrary SPIN: 4096-7048; ORCID: 0000-0002-7610-1743; e-mail: tvrogova@bakulev.ru

Darina Yu. Popenya, 6th-Year Student of the Pediatric Faculty; ORCID: 0009-0002-8566-9493; e-mail: darina_popenya@mail.ru

Maria P. Zhulikova, 6th-Year Student of the Pediatric Faculty; ORCID: 0009-0008-8941-8505; e-mail: marimarigu@yandex.ru

Contribution of the authors:

Timofeeva O.Yu. — collection of clinical material for the article, collection and analysis of data, writing the text; Akatov D.S. — processing of data; Glazunov A.Yu. — statistical processing; Grigoryants T.R. — analysis and interpretation of data; Kim A.I. — concept and design of the study; Rogova T.V. — концепция и дизайн исследования; Popenya D.Yu. — collection of clinical material; Zhulikova M.P. — preparation of the literature review. All authors approved the manuscript (the publication version), and also agreed to be responsible for all aspects of the work, ensuring proper consideration and resolution of issues related to the accuracy and integrity of any part of it.